

**AÇIK VE UZAKTAN ÖĞRENMEDE
ÖĞRENERLERİN DAVRANIŞ ÖRÜNTÜLERİNİN VE
PROFİLLERİNİN MODELLENMESİ,
AKADEMİK PERFORMANSLARININ TAHMİN EDİLMESİ VE
PERFORMANS DEĞERLENDİRME PANELİNİN
ETKİLERİNİN İNCELENMESİ**

Doktora Tezi

Aylin ÖZTÜRK

Eskişehir 2022

**AÇIK VE UZAKTAN ÖĞRENMEDE ÖĞRENENLERİN DAVRANIŞ
ÖRÜNTÜLERİNİN VE PROFİLLERİNİN MODELLENMESİ,
AKADEMİK PERFORMANSLARININ TAHMİN EDİLMESİ VE
PERFORMANS DEĞERLENDİRME PANELİNİN ETKİLERİNİN
İNCELENMESİ**

Aylin ÖZTÜRK

DOKTORA TEZİ

Uzaktan Eğitim Anabilim Dalı

Danışman: Prof.Dr. Alper Tolga KUMTEPE

Eskişehir

Anadolu Üniversitesi

Sosyal Bilimler Enstitüsü

Ocak 2022

Bu tez çalışması, TÜBİTAK Komisyonunca kabul edilen 1001-Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı kapsamındaki 118K100 no.lu proje ile desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Aylin ÖZTÜRK'ün “Açık ve Uzaktan Öğrenmede Öğrenenlerin Davranış Örüntülerinin ve Profillerinin Modellenmesi, Akademik Performanslarının Tahmin Edilmesi ve Performans Değerlendirme Panelinin Etkilerinin İncelenmesi” başlıklı tezi **14/01/2022** tarihinde aşağıdaki jüri tarafından değerlendirilerek “Anadolu Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği”nin ilgili maddeleri uyarınca, Uzaktan Eğitim Anabilim dalında Doktora tezi olarak kabul edilmiştir.

	<u>Unvanı Adı Soyadı</u>	<u>İmza</u>
Üye (Tez Danışmanı)	: Prof.Dr. Alper Tolga KUMTEPE
Üye	: Doç.Dr. Abdulkadir KARADENİZ
Üye	: Doç.Dr. Sinan AYDIN
Üye	: Doç.Dr. Esra Pınar UÇA GÜNEŞ
Üye	: Doç.Dr. İrfan SÜRAL

Prof.Dr. Saime ÖNCE
Anadolu Üniversitesi
Sosyal Bilimler Enstitüsü Müdürü

ÖZET

AÇIK VE UZAKTAN ÖĞRENMEDE ÖĞRENENLERİN DAVRANIŞ ÖRÜNTÜLERİNİN VE PROFİLLERİNİN MODELLENMESİ, AKADEMİK PERFORMANSLARININ TAHMİN EDİLMESİ VE PERFORMANS DEĞERLENDİRME PANELİNİN ETKİLERİNİN İNCELENMESİ

Aylin ÖZTÜRK

Uzaktan Eğitim Anabilim Dalı

Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Ocak 2022

Danışman: Prof.Dr. Alper Tolga KUMTEPE

Bu araştırmanın amacı, kitlesel açık ve uzaktan öğrenme sisteminde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin ve öğrenen profillerinin belirlenmesi, akademik performanslarına yönelik tahmin modeli geliştirilmesi, öğrenme yönetim sistemine entegre olarak çalışabilen öğrenme analitikleri tabanlı bir performans değerlendirme panelinin tasarlanması ve bu panelin öğrenme sürecindeki etkilerinin incelenmesidir. Anadolu Üniversitesi Açıköğretim Sisteminde gerçekleştirilmiş olan bu çalışmada, sisteme kayıtlı olan ve Anadolium eKampüs Öğrenme Yönetim Sistemini kullanan öğrenenlere ait verilerden yararlanılmıştır. Bu kapsamda çalışmada, öğrenenlerin demografik özellikleri, akademik performans puanları, öğrenme yönetim sistemindeki gezinme davranışlarından elde edilen veriler ve anket verileri kullanılmıştır.

Öğrenme malzemeleri kullanım örüntülerinin belirlenmesi için birliktelik kuralları kullanılmıştır. Kuralların çıktılarında çıkmış sınav soruları ve ünite özeti yer almıştır. Öğrenen profillerinin belirlenmesi için kümeleme analizi kullanılmıştır. k-Means algoritması ile öğrenenlerin dönem sonu ortalama puanları ve ortalama malzeme erişimleri göz önüne alınarak 5 küme elde edilmiştir. Öğrenenlerin akademik performanslarına yönelik tahmin modelinin geliştirilmesi için makine öğrenmesi ve derin öğrenme algoritmaları kullanılmıştır. Öğrenenlerin harf notları, GBT algoritmasıyla %72,16 doğrulukla tahmin edilmiştir. Tahmin modelinin geliştirilmesindeki en önemli değişkenler ise, ara sınav puanı ve sınava girme oranı olarak belirlenmiştir. Performans değerlendirme panelinin öğrenme sürecindeki etkilerinin belirlenmesi için deneysel bir çalışma yürütülmüştür. Yapılan testler

sonucunda, deney ve kontrol gruplarının ortalama oturum açma sayıları, oturum açtıkları gün sayıları, öğrenme malzemeleri erişim sayıları ve akademik performansları arasında istatistiksel olarak anlamlı bir farklılık olduğu belirlenmiştir.

Anahtar Sözcükler: Açık ve uzaktan öğrenme, Yapay zeka, Makine öğrenmesi, Öğrenme analitikleri, Performans değerlendirme paneli.

ABSTRACT

MODELING LEARNERS' BEHAVIORAL PATTERNS AND PROFILES, PREDICTING THE ACADEMIC PERFORMANCE AND INVESTIGATING THE EFFECTS OF A DASHBOARD IN OPEN AND DISTANCE LEARNING

Aylin ÖZTÜRK

Department of Distance Education

Anadolu University, Graduate School of Social Sciences, January 2022

Supervisor: Prof.Dr. Alper Tolga KUMTEPE

This research aims to determine the patterns of learning materials use, and profiles of learners utilizing learning management system (LMS) in a massive open and distance education system. This research also seeks to develop a prediction model for academic performance, and design, develop and evaluate a learning-analytics-based learner performance dashboard integrated with the LMS. Conducted within the Open Education System of Anadolu University, the study utilized data belonging to enrolled learners that utilize the Anadolom eKampüs Learning Management System. The study used various data resources including learner demographic data, academic performance grades, data from navigation behaviors on the LMS, and finally self-report questionnaire data.

Association rules were used to map the patterns of learning materials use. The outcome of the rules included previous exam questions and chapter summaries. Cluster analysis was utilized to map learner profiles. k-Means algorithm revealed 5 clusters depending on end-of-term average grades and average materials access. Machine and deep learning algorithms were used to develop prediction models for academic performance. Learner letter grades were predicted using the gradient boosted tree algorithm with an accuracy of 72.16%. The most important variables in developing the prediction model were mid-term grades and the rate of exam taking. Experimental study was conducted to investigate the effect of learner performance dashboard on learning processes. The tests revealed significant differences between the control and the experimental group in session time count, session day count, learning materials access count and academic performance.

Keywords: Open and distance learning, Artificial intelligence, Machine learning, Learning analytics, Dashboard.

ÖNSÖZ

Bu doktora tezinin öneri aşamasından tamamlanmasına kadar bilgi ve deneyim paylaşımları, destekleri ve yönlendirmeleri ile yanımda olan değerli Hocalarıma, arkadaşlarıma ve aileme teşekkürlerimi sunarım. Bu süreçte yanımda olan herkesin katkıları benim için çok kıymetliydi ve kendilerinden çok şey öğrendim.

Doktora sürecimin başından bu yana bilgi birikimini ve deneyimlerini benimle paylaşan, geri bildirimleri ve önerileriyle bana her zaman destek olan, bana güvendiğini ve daha iyisini yapabileceğimi hissettiren, özgür bir şekilde düşüncelerimi açıklamama olanak sağlayan, akademik dünyadaki duruşuna saygı duyduğum çok değerli tez danışmanım Prof.Dr. Alper Tolga Kumtepe'ye bu süreçteki yol göstericiliği için sonsuz teşekkürlerimi sunarım. Bu süreci kendisinin danışmanlığında sürdürmekten ve kendisiyle çalışmış olmaktan dolayı onur duyuyorum.

Tez izleme jürisi üyeleri Doç.Dr. Sinan Aydın ve Doç.Dr. İrfan Süral'a öneri aşamasından bu yana tezimin şekillenmesindeki önerileri ve katkıları, süreç boyunca gösterdikleri anlayış ve öğrenme sürecimdeki destekleri, tezimin değerlendirilmesine ayırdıkları zaman ve emekleri için şükranlarımı sunarım. Doç.Dr. İrfan Süral'a lisans eğitimimden bu yana cesaretimin kırıldığı anlarda beni desteklediği için teşekkürlerimi sunarım. Tez sürecindeki görüşleri ve önerileri bu tezin şekillenmesinde önemli katkılar sağladı. Doç.Dr. Sinan Aydın'a lisansüstü eğitimim boyunca öğrenme sürecime ve çalışmalarına olan destekleri ve tüm yoğunluğuna rağmen sorularımı hiçbir zaman yanıtsız bırakmadığı için sonsuz teşekkürlerimi sunarım. Uzaktan eğitim alanında çalışma alanımı belirlememde kendisinin katkıları yadsınamaz, veri bilimi alanındaki deneyimlerini benimle paylaştığı ve bana yol gösterdiği için Doç.Dr. Sinan Aydın'a teşekkürlerimi sunarım.

Bu tez çalışmasına destek olan TÜBİTAK'a teşekkürlerimi sunarım. Bu bağlamda başta proje yürütücüsü Prof.Dr. Alper Tolga Kumtepe olmak üzere araştırmacılar; Doç.Dr. Sinan AYDIN, Doç.Dr. İrfan SÜRAL, Dr. İhsan Güneş, Prof.Dr. Evrim Genç Kumtepe, Öğr.Gör. Ayfer Beylik, Doç.Dr. Abdulkadir Karadeniz'e ve proje danışmanları Doç.Dr. Gürkan Öztürk ve Prof.Dr. Arif Altun'a teşekkürlerimi sunarım.

Doktora eğitimim süresince açık ve uzaktan öğrenme alanında bilgi ve deneyimlerini benimle paylaşan ve bu alanda çalışmalar yapmama destek olan Anadolu Üniversitesi

Açıköğretim Sistemi Açık ve Uzaktan Eğitim bölümündeki tüm öğretim üyeleri ve elemanlarına teşekkürlerimi sunarım. Tez kapsamındaki uygulamanın gerçekleştirilmesi için yardımlarını esirgemeyen Prof.Dr. Volkan Yüzer'e teşekkür ederim. Tez kapsamındaki uygulamada destekleriyle yanımda olan Dr.Öğr.Üyesi Erdem Erdoğan'ya, tezime verdiği geri bildirim ve öneriler için Doç.Dr. Abdulkadir Karadeniz'e ve tezimle ilgili sorularına her zaman çözüm önerileri sunan kıymetli hocam Prof.Dr. Evrim Genç Kumtepe'ye teşekkürlerimi sunarım. Veri bilimi ve öğrenme yönetim sistemleri konularındaki uzmanlıklarıyla tez süreci boyunca desteklerini esirgemeyen çalışma arkadaşlarım Mustafa Kemal Birgin, Burak Mağden ve Hüseyin Kayhan'a teşekkürlerimi sunarım. Tezde grafik tasarım bilgilerini benimle paylaştıkları ve destekleri için Dilek Akyel ve Mehmet Gürsoy'a teşekkür ederim.

Tezimin geliştirilmesi için verdikleri öneriler, geri bildirimler, destekleri ve süreç boyunca yanımda oldukları için başta Ayfer Beylik olmak üzere sevgili arkadaşlarım Gamze Tuna Büyükköse, Selin Çöpgeven, Sinan Çakan ve Abdullah Saykılı'ya sonsuz teşekkürlerimi sunarım. Manevi destekleriyle yanımda olan Meltem Saykılı, Ezel Gündoğdu ve Ercüment Yılmaz'a teşekkür ederim.

Eğitim hayatımın şekillenmesinde büyük katkıları olan, ilkokuldan bu yana deneyimleri ve bilgi birikimi ile bana yeni kapılar açan değerli öğretmenim Güler Tan'a üzerimdeki emekleri ve bana olan güveni için sonsuz teşekkürlerimi sunarım.

Tüm hayatım boyunca bana ve fikirlerime değer verdikleri, kendi istediğim yolda yürümemi destekledikleri ve bunun için fırsatlar sundukları, sevgileri ve destekleriyle her zaman yanımda oldukları için annem Gülnar Öztürk ve babam Mustafa Öztürk başta olmak üzere canım aileme sonsuz teşekkürlerimi sunarım.

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Anadolu Üniversitesi tarafından kullanılan “bilimsel intihal tespit programıyla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....
Aylin ÖZTÜRK

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT.....	v
ÖNSÖZ	vii
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	ix
İÇİNDEKİLER	x
TABLolar DİZİNİ.....	xiv
ŞEKİLLER DİZİNİ.....	xv
GÖRSELLER DİZİNİ	xviii
SİMGELER VE KISALTMALAR DİZİNİ	xxi
1. GİRİŞ.....	1
1.1. Veri Analitiği	5
1.2. Öğrenme Analitikleri.....	6
1.3. Yapay Zeka.....	8
1.4. Sorun	12
1.5. Amaç.....	15
1.6. Önem	17
1.7. Sınırlılıklar.....	19
1.8. Tanımlar	21
1.9. Araştırma Bağlamı.....	23
1.9.1. Anadolu Üniversitesi Açıköğretim Sistemi	23
1.9.2. Anadolium eKampüs öğrenme yönetim sistemi	25
1.9.2.1. Özellikleri	25
1.9.2.2. Bileşenler ve öğrenme malzemeleri	27
1.9.2.3. Anadolium eKampüs kullanım oranları.....	40

2. ALANYAZIN	44
2.1. Çevrimiçi Öğrenme Ortamlarında Öğrenenlerin Davranış Örüntüleri	44
2.2. Çevrimiçi Öğrenme Ortamlarında Öğrenen Profilleri	46
2.3. Açık ve Uzaktan Öğrenmede Öğrenenlerin Akademik Performanslarının Tahmin Edilmesi	51
2.4. Çevrimiçi Öğrenme Ortamlarında Performans Değerlendirme Paneli Uygulamaları	55
3. YÖNTEM	62
3.1. Araştırma Modeli	62
3.2. Çalışma Kümesi	64
3.2.1. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi çalışma kümesi	64
3.2.2. Çevrimiçi öğrenme ortamında öğrenen profillerinin belirlenmesi çalışma kümesi	65
3.2.3. Akademik performans tahmin modelinin geliştirilmesi çalışma kümesi	66
3.2.4. Öğrenme analitikleri tabanlı performans değerlendirme paneli uygulaması çalışma kümesi	67
3.2.5. Öğrenme analitikleri tabanlı performans değerlendirme paneline yönelik öğrenen görüşlerinin belirlenmesi çalışma kümesi	69
3.3. Veri Kaynakları ve Veri Toplama Araçları	70
3.3.1. Çalışma veri ambarı	70
3.3.1.1. Öğrenci Bilgi Sistemi veritabanı	71
3.3.1.2. Öğrenme Yönetim Sistemi veritabanı	72
3.4. Araştırma Süreci	77
3.4.1. Tanımlayıcı analitik aşaması	77
3.4.1.1. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi	78
3.4.1.2. Çevrimiçi öğrenme ortamında öğrenen profillerinin belirlenmesi	83
3.4.2. Tahmin edici analitik aşaması	94
3.4.2.1. Akademik performans tahmin modelinin geliştirilmesi	95

3.4.3. Normatif Analitik Aşaması.....	115
3.4.3.1. Öğrenme analitikleri tabanlı performans değerlendirme panelinin geliştirilmesi	115
3.4.3.2. Öğrenme analitikleri tabanlı performans değerlendirme panelinin uygulanması	130
3.4.3.3. Öğrenme analitikleri tabanlı performans değerlendirme paneli kullanımının öğrenme sürecine etkilerinin belirlenmesi	136
3.4.3.4. Öğrenme analitikleri tabanlı performans değerlendirme paneline yönelik öğrenen görüşlerinin belirlenmesi.....	136
4. BULGULAR VE YORUM.....	137
4.1. Öğrenenlerin Öğrenme Malzemeleri Erişimlerinin İncelenmesi	137
4.2. Çevrimiçi Öğrenme Ortamında Öğrenenlerin Davranış Örüntülerinin Belirlenmesi	147
4.2.1. Apriori algoritması ile elde edilen davranış örüntüleri	147
4.2.2. CARMA algoritması ile elde edilen davranış örüntüleri.....	150
4.2.3. FP-Growth Algoritması ile elde edilen davranış örüntüleri.....	151
4.2.4. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntü modellerinin değerlendirilmesi.....	152
4.3. Çevrimiçi Öğrenme Ortamında Öğrenen Profillerinin Belirlenmesi	155
4.3.1. TwoStep Algoritması ile elde edilen öğrenen profilleri	156
4.3.2. k-Means Algoritması ile elde edilen öğrenen profilleri.....	166
4.3.3. Öğrenen profilleri modellerinin değerlendirilmesi	173
4.4. Akademik Performans Tahmin Modelinin Geliştirilmesi.....	179
4.4.1. Otomatik Modelleme ile elde edilen tahmin modelleri	179
4.4.2. GBT algoritması tahmin modeli	187
4.4.3. DL algoritması tahmin modeli	190
4.4.4. Akademik performans tahmin modellerinin değerlendirilmesi	192
4.5. Öğrenme Analitikleri Tabanlı Performans Değerlendirme Paneli Uygulaması.....	194
4.6. Öğrenme Analitikleri Tabanlı Performans Değerlendirme Paneli Uygulamasının Öğrenme Sürecine Etkileri.....	200

4.7. Öğrenme Analitikleri Tabanlı Performans Değerlendirme Paneline Yönelik Öğrenen Görüşlerinin Belirlenmesi	201
5. SONUÇ, TARTIŞMA VE ÖNERİLER	214
5.1. Sonuç ve Tartışma.....	214
5.1.1. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi	215
5.1.2. Çevrimiçi öğrenme ortamında öğrenen profillerinin belirlenmesi.....	219
5.1.3. Akademik performans tahmin modelinin geliştirilmesi	224
5.1.4. Öğrenme analitikleri tabanlı performans değerlendirme paneli uygulamasının öğrenme sürecine etkileri.....	227
5.1.5. Öğrenme analitikleri tabanlı performans değerlendirme paneli ile ilgili öğrenen görüşleri	229
5.2. Öneriler	232
KAYNAKÇA.....	237
EKLER	
ÖZGEÇMİŞ	

TABLULAR DİZİNİ

	<u>Sayfa</u>
Tablo 3.1. Örüntülerin belirlenmesinde kullanılan öznitelikler	80
Tablo 3.2. BIL102U toplam malzeme sayısının hesaplanması.....	121
Tablo 3.3. Motivasyonel erken müdahale stratejileri.....	124
Tablo 3.4. Alt gruplar bağlamında deney ve kontrol gruplarının dağılımı	131
Tablo 3.5. G_YEYN bağımsız örneklem t-testi sonuçları.....	131
Tablo 3.6. G_YEDN bağımsız örneklem t-testi sonuçları.....	132
Tablo 3.7. G_DEYN bağımsız örneklem t-testi sonuçları.....	132
Tablo 3.8. G_DEDN bağımsız örneklem t-testi sonuçları.....	133
Tablo 3.9. Tek yönlü ANOVA testi sonuçları	134
Tablo 4.1. Apriori algoritması ile elde edilen birliktelik kuralları (Güven değeri sıralı)...	148
Tablo 4.2. Profillerin belirlenmesinde girdi olarak kullanılan öznitelikler.....	173
Tablo 4.3. Algoritmalar bağlamında en yüksek tahmin gücüne sahip öznitelikler.....	193
Tablo 4.4. PDP mesaj örnekleri	195
Tablo 4.5. Mesajların okunma oranları.....	198
Tablo 4.6. Bağımsız örneklem t-testi sonuçları	200

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Yıl ve dönem bazında öğrenen sayıları	24
Şekil 1.2. Yaş gruplarına göre yıl ve dönem bazlı öğrenen sayıları	24
Şekil 1.3. Cinsiyetlere göre yıl ve dönem bazlı öğrenen sayıları	25
Şekil 1.4. Yıl ve dönem bazında Anadolu eKampüs tekil ve toplam giriş sayıları	40
Şekil 1.5. Yaş gruplarına göre yıl ve dönem bazlı Anadolu eKampüs giriş sayıları	41
Şekil 1.6. Cinsiyetlere göre yıl ve dönem bazlı Anadolu eKampüs giriş sayıları	42
Şekil 1.7. Yıl bazında öğrenme malzemelerine tekil ve toplam erişim sayıları	43
Şekil 3.1. Örüntülerin belirlenmesi çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları	65
Şekil 3.2. Tahmin modelinin geliştirilmesi çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları	67
Şekil 3.3. PDP uygulaması çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları	68
Şekil 3.4. Anket çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları	69
Şekil 3.5. Görselleştirilmiş korelasyon matrisi	89
Şekil 3.6. Öznitelik seçimi sonuçları	91
Şekil 3.7. Görselleştirilmiş korelasyon matrisi	103
Şekil 4.1. Öğrenenlerin öğrenme malzemelerine toplam ve ortalama erişimleri	137
Şekil 4.2. Öğrenenlerin yaş gruplarına göre öğrenme malzemelerine toplam ve ortalama erişimleri	138
Şekil 4.3. Öğrenenlerin genel not ortalamalarına göre öğrenme malzemelerine toplam ve ortalama erişimleri	140
Şekil 4.4. Öğrenenlerin kayıt türlerine göre öğrenme malzemelerine toplam ve ortalama erişimleri	141
Şekil 4.5. Öğrenenlerin aylara göre öğrenme malzemelerine toplam ve ortalama erişimleri	142
Şekil 4.6. Öğrenenlerin aylara göre öğrenme malzemeleri bazlı toplam ve ortalama erişimleri	143

Şekil 4.7. Öğrenenlerin haftalara göre öğrenme malzemelerine toplam ve ortalama erişimleri	144
Şekil 4.8. Öğrenenlerin günlere göre öğrenme malzemelerine toplam ve ortalama erişimleri	145
Şekil 4.9. Öğrenenlerin haftalara göre öğrenme malzemelerine toplam ve ortalama erişimleri	146
Şekil 4.10. Öğrenme malzemeleri arasındaki ilişkiler.....	152
Şekil 4.11. k-Means sonuçları ısı haritası.....	169
Şekil 4.12. Kümelerin cinsiyet ve yaş dağılımları.....	175
Şekil 4.13. Kümelerin ilk oturum açma tarihleri.....	176
Şekil 4.14. Grupların ortalama sınav puanları ve ortalama sistem kullanımları	177
Şekil 4.15. Grupların öğrenme malzemeleri erişimleri	178
Şekil 4.16. Tahmin modeli geliştirme analiz sonuçları	181
Şekil 4.17. Naive Bayes algoritması performans sonuçları.....	182
Şekil 4.18. GLM algoritması performans sonuçları	182
Şekil 4.19. FLM algoritması performans sonuçları.....	183
Şekil 4.20. DT algoritması performans sonuçları.....	184
Şekil 4.21. LR algoritması performans sonuçları	184
Şekil 4.22. RF algoritması performans sonuçları	185
Şekil 4.23. DL algoritması performans sonuçları.....	186
Şekil 4.24. GBT algoritması performans sonuçları	187
Şekil 4.25. GBT algoritması performans sonuçları	188
Şekil 4.26. DL algoritması performans sonuçları.....	191
Şekil 4.27. Mesaj okuma işlemi sonrasında öğrenenlerin öğrenme malzemeleri erişimi ..	199
Şekil 4.28. Öğrenenlerin cinsiyet ve yaşları bağlamında PDP'yi inceleme durumları	202
Şekil 4.29. Öğrenenlerin harf notları bağlamında PDP'yi inceleme durumları	203
Şekil 4.30. Öğrenenlerin cinsiyet ve yaşları bağlamında mesajları okuma durumları	204
Şekil 4.31. Öğrenenlerin harf notları bağlamında mesaj okuma durumları	205
Şekil 4.32. PDP'ye yönelik algılanan fayda.....	206
Şekil 4.33. PDP kullanılabilirliğine yönelik görüşler	207
Şekil 4.34. Mesajlara yönelik algılanan fayda.....	208

Şekil 4.35. Mesajların kullanılabilirliğine ilişkin görüşler.....	209
Şekil 4.36. PDP'ye yönelik memnuniyet	210

GÖRSELLER DİZİNİ

Sayfa

Görsel 1.1. Analitik türleri (Hagerty, 2017).....	5
Görsel 1.2. Öğrenme Analitikleri Taksonomisi (Peña-Ayala, 2018).....	7
Görsel 1.3. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi (Copeland, 2016) ...	10
Görsel 1.4. Anadolom eKampüs giriş sayfası.....	26
Görsel 1.5. Anadolom eKampüs anasayfası	27
Görsel 1.6. Derslerim ekranı	28
Görsel 1.7. Sınavlar sekmesi.....	28
Görsel 1.8. Deneme sınavı ekranı	29
Görsel 1.9. Kitap örneği	30
Görsel 1.10. Ünite örneği	31
Görsel 1.11. Konu tabanlı video örneği	32
Görsel 1.12. Soru tabanlı video örneği.....	32
Görsel 1.13. Animasyon tabanlı video örneği.....	33
Görsel 1.14. Etkileşimli içerik örneği	33
Görsel 1.15. Canlı ders örneği.....	34
Görsel 1.16. İnfografik ve çıkmış sınav soruları örnekleri	35
Görsel 1.17. Sorularla öğrenelim örneği	36
Görsel 1.18. Alıştırma örneği.....	36
Görsel 1.19. Öğrenci toplulukları ekranı.....	37
Görsel 1.20. Kayıtlı malzemeler ekranı	38
Görsel 1.21. Takvim ekranı.....	39
Görsel 1.22. Bilgilendirme ekranı.....	39
Görsel 3.1. Çalışmanın aşamaları.....	63
Görsel 3.2. Çalışmanın veri ambarı yapısı	71
Görsel 3.3. Öğrenci Bilgi Sistemi veritabanı yapısı.....	72
Görsel 3.4. Öğrenme Yönetim Sistemi veritabanı yapısı.....	73
Görsel 3.5. Tüm Faaliyet tablosunda yer alan alanlar.....	75

Görsel 3.6. Örüntülerin belirlenmesi veri hazırlama süreci	79
Görsel 3.7. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-I	84
Görsel 3.8. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-II	85
Görsel 3.9. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-III	86
Görsel 3.10. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-IV	87
Görsel 3.11. Veri temizleme ve veri keşfi süreci	88
Görsel 3.12. Öznitelik seçim süreci	91
Görsel 3.13. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-I	96
Görsel 3.14. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-II	97
Görsel 3.15. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-III	98
Görsel 3.16. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-IV	99
Görsel 3.17. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-V	100
Görsel 3.18. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-VI	101
Görsel 3.19. Tahmin modeli veri setinde veri ön işleme süreci	102
Görsel 3.20. Otomatik öznitelik mühendisliği süreci	105
Görsel 3.21. Gözetimli öğrenme süreci	106
Görsel 3.22. DT algoritması parametre değerleri	109
Görsel 3.23. RF algoritması parametre değerleri	110
Görsel 3.24. GBT algoritması parametre değerleri	111
Görsel 3.25. Derin sinir ağı yapısı	112
Görsel 3.26. DL algoritması parametre değerleri	114
Görsel 3.27. PDP taslak tasarım-I	117
Görsel 3.28. PDP taslak tasarım-II	118
Görsel 3.29. PDP taslak tasarım-III	119
Görsel 3.30. Geri bildirim mesajlarında kullanılan arka plan örnekleri	125
Görsel 3.31. Geri bildirim mesaj kuralları giriş ekranı	126
Görsel 3.32. Mesaj oluşturma ekranı	127
Görsel 3.33. PDP nihai tasarımı	128
Görsel 3.34. PDP nihai tasarımının ÖYS entegrasyonu	129
Görsel 4.1. Apriori algoritması uygulama ekranı	147
Görsel 4.2. CARMA algoritması uygulama ekranı	150

Görsel 4.3. FP-Growth algoritması uygulama ekranı	151
Görsel 4.4. Kümeleme analizi öznelik tablosu	156
Görsel 4.5. Otomatik kümeleme sonuçları.....	157
Görsel 4.6. TwoStep düğüm ekranı.....	158
Görsel 4.7. TwoStep analizleri-I	159
Görsel 4.8. TwoStep analizleri-II.....	160
Görsel 4.9. TwoStep analizleri-II sonucu	160
Görsel 4.10. TwoStep analizleri-III	161
Görsel 4.11. TwoStep analizi-III sonucu	162
Görsel 4.12. k-Means algoritması işlem adımları	167
Görsel 4.13. k-Means küme dağılımları.....	168
Görsel 4.14. GBT algoritması uygulama ekranı	188
Görsel 4.15. DL algoritması uygulama ekranı	191

SİMGELER VE KISALTMALAR DİZİNİ

AÖS	: Anadolu Üniversitesi Açıköğretim Sistemi
BIL101U	: Temel Bilgi Teknolojileri I
BIL102U	: Temel Bilgi Teknolojileri II
DL	: Deep Learning
DT	: Decision Tree
FLM	: Fast Large Margin
G_DEDN	: Düşük Erişim Düşük Not Grubu
G_DEYN	: Düşük Erişim Yüksek Not Grubu
G_YEDN	: Yüksek Erişim Düşük Not Grubu
G_YEYN	: Yüksek Erişim Yüksek Not Grubu
GBT	: Gradient Boosted Trees
GLM	: Generalized Linear Model
LR	: Logistic Regression
NB	: Naive Bayes
ÖYS	: Öğrenme Yönetim Sistemi
RF	: Random Forest
t_ODF	: Oturum ve Ders Bazlı Faaliyet Tablosu
t_ODFö	: Oturum ve Ders Bazlı Faaliyet Özet Tablosu
t_ODFö_AS	: Oturum ve Ders Bazlı Faaliyet Özet Tablosu_Arasınav
t_ODFö_DS	: Oturum ve Ders Bazlı Faaliyet Özet Tablosu_DönemSonu
t_OF	: Oturum Bazlı Faaliyet Tablosu
t_OFö	: Oturum Bazlı Faaliyet Özet Tablosu
t_OFö_AS	: Oturum Bazlı Faaliyet Özet Tablosu_Arasınav
t_OFö_DS	: Oturum Bazlı Faaliyet Özet Tablosu_DönemSonu
t_ÖBS	: Öğrenci Bilgi Sistemi Tablosu
t_Örüntü	: Örüntü Modeli Tablosu
t_Profil	: Profil Modeli Tablosu
t_TF	: Tüm Faaliyet Tablosu
t_TM	: Tahmin Modeli Tablosu

1. GİRİŞ

Çevrimiçi öğrenme ortamlarını kullanan öğrenen sayılarının artmasına paralel olarak öğrenenlerin öğrenme süreçlerindeki hareketlerine yönelik pek çok veri ortaya çıkmaktadır. Veri bilimi alanındaki uygulamaların eğitim alanına entegre olmasıyla öğrenenlerin çevrimiçi öğrenme ortamlarındaki her türlü etkileşimine yönelik veri kayıt altına alınabilmekte ve öğrenme süreci takip edilebilmektedir. Öğrenenlerin çevrimiçi öğrenme ortamlarında yaptıkları her hareket ve etkileşim dijital ayak izi olarak değerlendirilmekte ve bu dijital ayak izleri öğrenme sürecine ait büyük veriyi oluşturmaktadır (Azcona vd., 2019). Çevrimiçi öğrenme ortamlarında toplanan öğrenmeye ait büyük veri, öğrenmeyi daha önce hiç olmadığı kadar anlama ve optimize etme fırsatı sunmaktadır (Du vd., 2021; Jivet vd., 2020; Leitner vd., 2017; Macfadyen ve Dawson, 2010). Bu büyük veri, öğrenenlerin öğrenme deneyimlerini iyileştirmek ve öğrenme sürecindeki paydaşların karar verme süreçlerini desteklemek için kullanılabilir (Aljohani vd., 2019; Macfadyen ve Dawson, 2012; Matcha vd., 2019). Ayrıca bu verilerin anlamlandırılması öğrenenlerin, öğretmenlerin ve kurumların öğrenme sürecine yönelik farklı bakış açıları geliştirmelerine de olanak tanıyabilir (Mouaici vd., 2018). Öğrenenlerin dijital ayak izlerinin kayıt altına alınması kadar analiz edilmesi ve anlamlandırılması da oldukça önemlidir (Naranjo vd., 2019). Dijital ayak izlerinin potansiyelinden yararlanmak için öğrenme sürecindeki verilerin ölçümüne, toplanmasına, analizine, görselleştirilmesine ve raporlanmasına odaklanan öğrenme analitiği (Siemens, 2011) yöntem ve teknikleri kullanılabilir (Matcha vd., 2019). Öğrenme analitiği, veri analitiği alanının bir alt kümesi olarak ifade edilebilir (Pelletier vd., 2021). Öğrenme analitiğinin yükseköğretim kurumlarında kullanılması, öğretme ve öğrenme süreçlerine ait verinin artışı sebebiyle ihtiyaç haline gelmiştir (Pelletier vd., 2021; Siemens ve Baker, 2012). Bu kapsamda ele alındığında öğrenme analitiklerinin öğrenenlerin ihtiyaçlarını belirlemek, sistemdeki davranışlarını daha iyi anlamak, öngörülerde bulunmak ve öğrenme süreçlerini iyileştirmek amacıyla kullanıldığı söylenebilir.

Öğrenme analitikleri, öğrenenlerin öğrenme süreçlerinin dijital olarak tanımlanmasına ve detaylı bir şekilde takip edilmesine olanak sağlamaktadır. Bu sayede öğrenme ve öğretme süreci hakkında bilgiler ortaya çıkarılabilmektedir. Öğrenme analitikleri çalışmalarının temel odak noktasının öğrenme deneyimlerinin iyileştirilmesi olduğu söylenebilir. Öğrenme

analitikleri; öğrenme süreçlerini inceleme, öğrenenlerin davranışlarını ve deneyimlerini tanımlama, öğrenenlerin ilerleme durumlarını, motivasyonlarını, tutum ve memnuniyetlerini veriye dayalı olarak değerlendirme olanağı sağlamaktadır (Mangaroska ve Giannakos, 2019). Bu yapısıyla öğrenme analitikleri, öğrenme ve öğretme sürecini anlamlandırmada kritik bir role sahiptir (Gašević vd., 2015; Mangaroska ve Giannakos, 2019). Öğrenme analitikleri; beklenmedik öğrenme davranışlarını açıklama, başarılı öğrenme modellerini belirleme, öğretim kalitesini belirleme, öğrenenlerin zorlandıkları bölümleri tespit etme, problem durumuna uygun müdahaleler sunma ve öğrenenlerin kendi eylemlerine ilişkin farkındalıklarını artırma potansiyeline sahiptir (Joksimović vd., 2019; Siemens ve Long, 2011).

Yapay zeka, makine öğrenmesi, büyük veri ve algoritmaların deneyimleri şekillendirdiği algoritmik çağda öğrenme analitikleri çalışmalarının gerçekleştirilmesinde, öğrenme analitikleri ile yapay zeka yöntem ve tekniklerinin birlikte kullanıldığı görülmektedir (Pelletier vd., 2021). Yapay zeka, bilgisayarların ve makinelerin insan bilişini ve eylemlerini taklit etme yeteneği olarak tanımlanabilir (Wartman ve Combs, 2018). Yapay zeka, problem çözme ve örüntü tanıma gibi insan zekası ile yaygın olarak ilişkili bilişsel problemleri çözmeyi ve ardından bu çözümleri uyarlamayı amaçlayan bir çalışma alanıdır (Chassigno vd., 2018). Yükseköğretimde yapay zeka; analitikler, robot yazarlar, sanal deneyimler ve zeki öğretim sistemleri gibi yenilikçi sistemlerin temelini oluşturmaktadır (Riedel vd., 2017). Yapay zeka eğitim kurumlarında idari süreçlerin ve görevlerin otomasyonu, program ve içerik geliştirme, öğretme ve öğrenme süreçlerinin iyileştirilmesi alanlarında kullanılmaktadır (Chen vd., 2020). Buna ek olarak, eğitim alanındaki yapay zeka uygulamalarında makine öğrenmesi, derin öğrenme ve yapay sinir ağlarının kullanılması öğretme ve öğrenme süreçlerini destekleyen yeni araçların geliştirilmesine de olanak sağlayabilir (Riedel vd., 2017).

Öğrenme analitiği alanında yapılan çalışmalar performans tahmini, öğretene ve öğrenenler için karar desteği, öğrenen davranışlarının belirlenmesi, öğrenenlerin modellenmesi ve sistemden ayrılmaya yönelik tahmin edici analizler konularında yoğunlaşmaktadır (Du vd., 2021). Yükseköğretimdeki öğrenenler yaş, kültürel ve sosyoekonomik geçmiş, motivasyon ve teknolojiyle ilgili genel deneyim açısından giderek daha çeşitli hale gelmektedirler. Özellikle öğrenen çeşitliliğinin yüksek olduğu açık ve

uzaktan öğrenme sistemlerinde öğrenen özelliklerinin belirlenmesi, öğrenen ihtiyaçları gözetilerek iyileştirme ve geliştirme yapılmasına olanak sağlayabilir. Bu bağlamda, açık ve uzaktan öğrenme sistemlerinde öğrenenlerin davranış örüntülerinin belirlenmesi ve öğrenen profillerinin tanımlanabilmesi yönünde çalışmaların yapıldığı görülmektedir (Du vd., 2021; Romero ve Ventura, 2020). Bunlar, var olan durumun ortaya çıkmasını sağlayan *tanımlayıcı analitik* kapsamında değerlendirilmektedirler (IBM, 2017).

Öğrenme analitikleri öğrenme deneyimini iyileştirmek için verilere geriye doğru bakmak kadar, gelecekteki öğrenen davranışlarını tahmin etmek ve potansiyel sorunları tanımlayabilmek amacıyla da kullanılmaktadır (Goode vd., 2021). Çevrimiçi öğrenme ortamındaki öğrenen davranışlarına yönelik derinlemesine bilgi elde edilmesi ve bu durumun öğrenenlerin akademik performanslarına nasıl etki ettiğinin anlaşılması, öğrenme sürecinin geliştirilmesi açısından oldukça önemlidir. Buna yönelik olarak öğrenme analitikleri alanında yaygın olarak gerçekleştirilen çalışmalardan biri, öğrenen performanslarının tahmin edilmesidir (Peña-Ayala, 2014; Romero ve Ventura, 2013). Gelecekte neler olacağına yönelik tahmin modelleri ve öngörülerin sunulduğu bu çalışmalar, veri analitiğinin *tahmin edici analitik* boyutunda ele alınmaktadır (IBM, 2017).

Tanımlayıcı ve tahmin edici analitik çalışmalarında yaygın olarak yapay zekanın alt dallarından olan makine öğrenmesi ve derin öğrenme algoritmaları kullanılmaktadır (Ciolacu vd., 2017). Tanımlayıcı ve tahmin edici analitik çalışmaları ile öğrenme sürecine yönelik önemli bilgiler keşfedilebilmektedir. Ancak yapılan çalışmaların çoğunlukla tek bir derste ve az sayıdaki öğrenen grupları ile gerçekleştirildiği görülmektedir (Örn; Cerezo vd., 2016; Hogo, 2010; Romero, López vd., 2013; You, 2016; Yukselturk ve Top, 2013). Öğrenme analitikleri çalışmaları incelendiğinde daha kapsamlı analizler için veri eksikliği yaşandığı, farklı veri kaynaklarından elde edilen verilerin kullanılması ile daha anlamlı ve genellenebilir sonuçların ortaya çıkabileceği değerlendirilmektedir (Amershi ve Conati, 2009; Jovanovic vd., 2012; Yukselturk ve Top, 2013).

Öğrenme analitiklerinde öğrenenlere ait veriler kullanılmakla birlikte geliştirilen uygulamaların çoğunlukla kurum yöneticileri, öğretmenler ve idari personellere yönelik olduğu (Pelletier vd., 2021); ancak öğrenenlere sunulan öğrenme analitiği çalışmalarının az sayıda olduğu görülmektedir (Bodily ve Verbert, 2017). Oysa öğrenenlerin öğrenme analitikleri ile keşfedilen bilgileri, kendi öğrenme süreçlerine yol gösterecek şekilde

anlamlandırabilmeleri ve yorumlayabilmeleri öğrenme deneyimlerine katkı sağlayabilir. Açık ve uzaktan öğrenenler genellikle öğrenme yönetim sistemindeki hareketleri ve ilerleme durumları hakkında bilgi sahibi değildirler. Öğrenenlere ilerleme durumları hakkında bilgi vermek ve ders kazanımlarına ulaşmaları için stratejiler sunmak, önemli bir öğrenme analitiği uygulamasıdır. Ancak büyük veri analizi ile geliştirilen modellerin öğrenenler tarafından anlamlandırılması ve yorumlanması zor olabilmektedir (Conde vd., 2015; Duval, 2011; Xing vd., 2015). Bu durumun üstesinden gelebilmek için veri görselleştirme yöntemleri kullanılabilir. Öğrenme ortamlarında öğrenenlerin öğrenme sürecindeki davranışlarını görselleştirmek ve raporlamak için yaygın olarak kullanılan araçlardan biri, öğrenme analitiklerine dayalı performans değerlendirme panelleridir (PDP) (Jivet vd., 2017; Kemsley, 2020; Knight vd., 2015; Roberts vd., 2017).

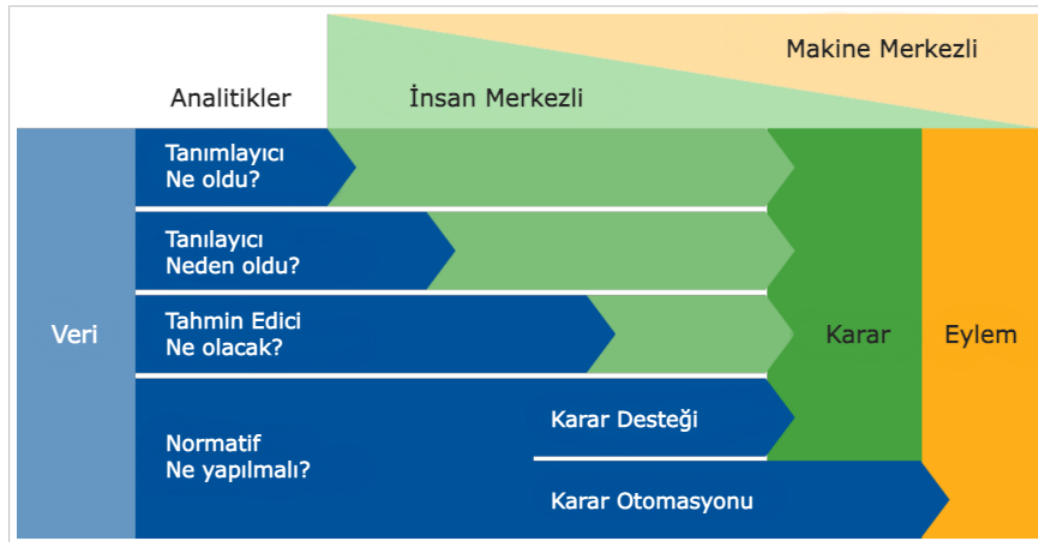
Öğrenme analitiklerinin *normatif* boyutunda (IBM, 2017) değerlendirilebilecek PDP'ler; öğrenme sürecinin geliştirilmesi, iyileştirilmesi ve karar süreçlerinin desteklenmesi açısından önemlidir (Park ve Jo, 2019). Bu durum özellikle öğretene ve öğrenenlerin fiziksel olarak ayrı olduğu çevrimiçi öğrenme ortamlarında ön plana çıkmaktadır (Park ve Jo, 2019). Öğrenme analitiği alanında verilerin analiz edilmesi ve modellerin geliştirilmesinin yanı sıra eyleme yönelik çalışmalar da planlanmalıdır (Khalil ve Ebner, 2015). Bu bağlamda PDP'lerin pasif bilgi gösterimleri olmanın ötesine geçmesi ve öğrenenlerin harekete geçmelerini sağlayan eylem desteğini de içermesi gerektiği söylenebilir. Bu açıdan değerlendirildiğinde erken müdahale uygulamaları, geri bildirim bileşeni ile öğrenenlerin önceden bilgilendirilmelerine ve böylece eyleme geçmelerine destek olabilir. Öğrenenlere öğrenme etkinliklerine katılımları ve performansları hakkında doğrudan geri bildirim sağlamak, öğrenmeyi desteklemeye ve iyileştirmeye katkı sunabilir (Corrin ve De Barba, 2015). PDP'ye yönelik çalışmalar incelendiğinde, tanımlayıcı ve tahmin edici analitik aşamalarına benzer olarak, büyük ölçekli çalışmalar yapılması gerektiği ve bu uygulamaların heterojen kitleler üzerindeki etkisinin araştırılmasının vurgulandığı görülmektedir (Jivet vd., 2020). Özetle, öğrenme analitikleri çalışmalarında genelleştirilebilir ve aktarılabilir bulgular üretmek için büyük ölçekli, boylamsal ve deneysel araştırmalara odaklanılması gerektiği söylenebilir (Ifenthaler ve Yau, 2020).

Bu çalışma, veri analitiğinin üç boyutu olan tanımlayıcı, tahmin edici ve normatif analitik üzerine yapılandırılmıştır. Tanımlayıcı analitik aşamasında, kitlesel açık ve uzaktan

öğrenme sisteminde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin belirlenmesi ve öğrenen profillerinin oluşturulması hedeflenmektedir. Tahmin edici analitik aşamasında öğrenenlerin bir dersteki akademik performanslarına yönelik tahmin modelinin geliştirilmesi amaçlanmaktadır. Son aşama olan normatif analitik aşamasında ise, bir öğrenme yönetim sistemine entegre olarak çalışabilen PDP'nin geliştirilmesi ve öğrenme sürecindeki etkilerinin incelenmesi hedeflenmektedir. Bu süreçlerde analizlerin gerçekleştirilmesi ve modellerin geliştirilmesinde makine öğrenmesi ve derin öğrenme yöntem ve teknikleri kullanılmış, PDP'nin etkilerinin belirlenmesi amacıyla ise deneysel tasarım uygulanmıştır.

1.1. Veri Analitiği

Analitik; verilerdeki ilişkileri keşfetmeyi, anlamlı örüntüler bulmayı, bilinmeyen sonuçları tahmin etmeyi ve kararları otomatikleştirmeyi amaçlayan bir bilgisayar bilimi alanıdır (SAS, 2021c). Veri analitiğinde yeni bilgileri ortaya çıkarmak için uygulamalı matematik, istatistik, yapay zeka, tahmine dayalı modelleme ve makine öğrenmesi gibi pek çok disiplinin özellikleri kullanılmaktadır (SAS, 2021c). Analitik türleri; tanımlayıcı (descriptive), tanılayıcı (diagnostic), tahmin edici (predictive) ve normatif (prescriptive) olmak üzere 4 boyutta incelenebilir (Hagerty, 2017). Analitik türleri, Görsel 1.1'de verilmiştir.



Görsel 1.1. Analitik türleri (Hagerty, 2017)

Tanımlayıcı analitikte, veriler analiz edilerek var olan durum ortaya konulmaktadır (IBM, 2017). Bu analitik türü ile “Ne oldu, problem nedir, ne sıklıkla ve nerede yaşanmaktadır?” gibi sorulara yanıt aranmaktadır (IBM, 2017). Tanılayıcı analitikte ise “Neden oldu?” sorusunu yanıtlamak için veri keşfi, veri madenciliği ve korelasyon gibi teknikler kullanılarak veriler incelenmektedir.

Tahmin edici analitikte var olan veriler üzerinde analiz yapılarak tahminler geliştirilmektedir (Han vd., 2012). “Gelecekte ne olacak, eğilim devam ederse neler yaşanacak, neler olabilir, hangi eylemlere gerek duyuluyor?” gibi sorulara yanıt aranan tahmin edici analitikler ile tahmin modelleri ve öngörüler oluşturulmaktadır (IBM, 2017). Normatif analitik, “Ne yapılmalı?” sorusu ile ilgilenmektedir. Bunun için tanımlayıcı ve tahmin edici analitiklere dayalı olarak olası eylemler keşfedilmekte ve önerilmektedir (IBM, 2017). Normatif analitikte simülasyon, öneri motorları, makine öğrenmesi, karmaşık olay akışı işleme ve sezgisel yöntemler kullanılmaktadır (Gartner, 2021).

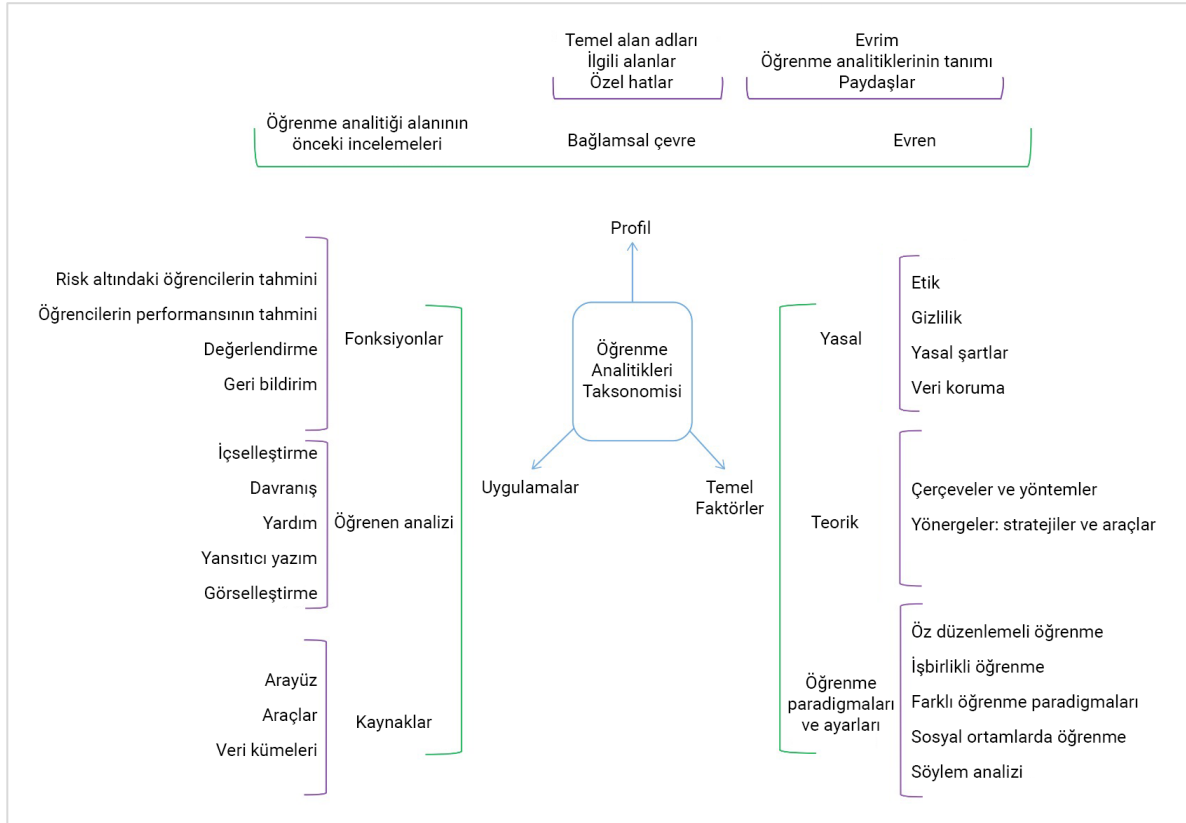
1.2. Öğrenme Analitikleri

Öğrenme analitikleri, veri analitiği alanının bir alt kümesi olarak ifade edilebilir (Pelletier vd., 2021). Öğrenme analitikleri öğrenmeyi geliştirmek için büyük veri tekniklerinin uygulaması olarak değerlendirilebilir (Clow, 2013). Öğrenme analitiklerinin yükseköğretim kurumlarında kullanılması, öğretme ve öğrenme süreçlerine ait verinin artışı sebebiyle ihtiyaç haline gelmiştir (Pelletier vd., 2021; Siemens ve Baker, 2012). Dijital çağda eğitim kurumlarının karşılaştığı en büyük zorluklardan biri, eğitim verilerinin katlanarak büyümesi ve bu verilerin tüm paydaşlara fayda sağlayabilecek yeni anlayışlara dönüştürülmesinde yaşanan sorunlardır (Baker, 2015). Öğrenme analitikleri ve veri analitiği yöntem ve teknikleri kullanılarak öğrenme ve öğretme süreçlerine yönelik yeni bilgiler ortaya çıkarılabilir ve farklı uygulamalar gerçekleştirilebilir. Bunun yanı sıra, öğrenme analitiklerinin eğitimi dönüştürme potansiyeli de bulunmaktadır (Siemens ve Long, 2011).

Siemens ve Baker (2012), öğrenme analitiklerini “öğrenenler ve öğrenme ortamına ilişkin verilerin öğrenmenin ve öğrenmenin gerçekleştiği ortamın daha iyi anlaşılması ve optimize edilmesi amacıyla ölçülmesi, toplanması, analiz edilmesi ve raporlanması” olarak

tanımlarken Peña-Ayala vd. (2017), “öğrenme deneyimlerinin etkinliğini ve öğrenenlerin başarılarını artırmak için bilgisayar tabanlı eğitim ortamlarında meydana gelen öğrenme olgusunu hem deneysel hem de davranışsal açılardan incelemek, tanımlamak, açıklamak ve tahmin etmek için yürütülen bir araştırma süreci” olarak tanımlamaktadır. Öğrenme analitiklerinde öğrenme süreci hakkında geri bildirim ve farkındalık sağlamak için veri görselleştirme, öğrenme bilimleri, yazılım mühendisliği, istatistik ve veri madenciliği yöntemlerinden yararlanılmaktadır (Pijera Díaz vd., 2016). Öğrenme analitikleri, öğrenenlerin öğrenme süreçlerini daha iyi desteklemek ve anlamak için bir yaklaşım sunmaktadır (Schumacher ve Ifenthaler, 2018).

Peña-Ayala (2018) tarafından öğretme ve öğrenme uygulamalarını iyileştirmek, öğrenme analitikleri araştırmaları ve eğilimleri hakkında bilgi vermek amacıyla Öğrenme Analitikleri Taksonomisi geliştirilmiştir (Görsel 1.2). Bu taksonomi profil, temel faktörler ve uygulama kategorileri ve bunların alt bölümlerinden oluşmaktadır.



Görsel 1.2. Öğrenme Analitikleri Taksonomisi (Peña-Ayala, 2018)

Öğrenme analitikleri süreci veri çekme, veri düzenleme, analiz, sunum ve görselleştirme, eylem ve geliştirme aşamalarından oluşmaktadır (Campbell ve Oblinger, 2007; Siemens, 2013). Öğrenme analitiklerinde çevrimiçi öğrenme ortamlarından elde edilen dijital ayak izleri, etkileşim verileri, forum ve tartışma alanlarındaki mesaj verileri, Öğrenci Bilgi Sistemlerinden elde edilen kişisel veriler, akademik performanslar ve anket gibi veri toplama araçlarından elde edilen veriler kullanılmaktadır. Öğrenme analitikleri çalışmalarında yaygın olarak kullanılan yöntemler ise etken analizi, kümeleme, modellerle keşfetme, tahmin, süreç madenciliği, öneri sistemleri, ilişki madenciliği ve bilgi izleme olarak belirtilebilir (Romero ve Ventura, 2020). Bu veriler ve yöntemler kullanılarak öğrenme analitiği alanında yapılan çalışmalar; performans tahmini, öğreten ve öğrenenler için karar desteği, öğrenen davranışlarının belirlenmesi, öğrenenlerin modellenmesi ve sistemden ayrılmaya yönelik tahmin edici analizler konularında yoğunlaşmaktadır (Du vd., 2021).

Öğrenme analitiğinin paydaşları öğrenenler, öğretenler, araştırmacılar, yöneticiler ve eğitim kurumlarıdır (Romero ve Ventura, 2020). Öğrenme analitikleri, öğrenenlerin öğrenme sürecinde desteklenmelerine, zorlandıkları noktaların belirlenmesine, öğrenme deneyimlerinin iyileştirilmesine olanak sağlama potansiyeline sahiptir. Öğrenme analitikleri ile öğretenler, öğrenme sürecini inceleyerek öğretim yöntemlerini geliştirebilirler. Araştırmacılar gerçekleştirilen öğrenme analitikleri uygulamaların etkililiğini değerlendirebilir ve yeni uygulamalar tasarlayabilirler. Yöneticiler ve eğitim kurumları ise öğrenme analitikleri uygulamaları için kaynakların ayarlanmasına destek olabilirler (Romero ve Ventura, 2020).

1.3. Yapay Zeka

Yapay zeka, bilgisayarların ve makinelerin insan bilişini ve eylemlerini taklit etme yeteneği olarak tanımlanabilir (Wartman ve Combs, 2018). Yapay zeka, problem çözme ve örüntü tanıma gibi insan zekası ile yaygın olarak ilişkili bilişsel problemleri çözmeyi ve ardından uyarlamayı amaçlayan bir çalışma alanıdır (Chassigno vd., 2018). Yapay zeka olayları yorumlamak, kararları desteklemek, otomatikleştirmek ve eyleme geçmek için makine öğrenmesi gibi gelişmiş analiz yöntemlerini uygulamaktadır. Yapay zekanın alt

alanları; makine öğrenmesi, bilgisayarla görme, doğal dil işleme teknolojileri, robotik, bilgi temsili gibi bilimsel alanları içermektedir (Hajkowicz vd., 2019).

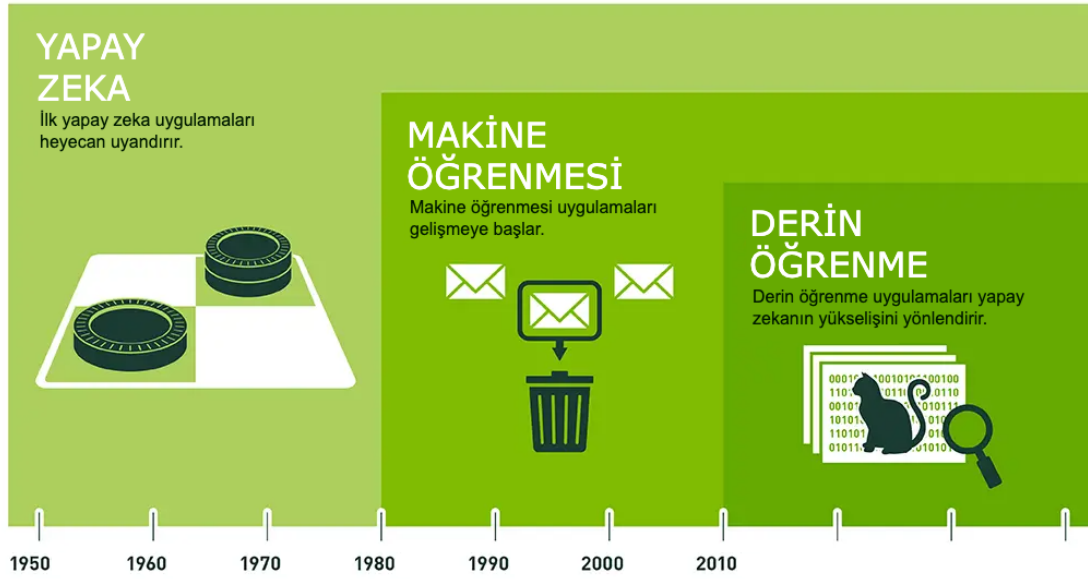
Yapay zeka sağlıktan otomotive, pazarlamadan finansa kadar pek çok alanı etkilemiş ve çalışma şekillerinde değişiklik yaratmıştır. Yapay zeka uygulamalarına yüz algılama ve tanıma, otonom sürüş sistemleri, akıllı asistanlar, konuşma tanıma, dil algılama ve çevirme sistemleri, öneri sistemleri ve üretim robotları örnek verilebilir. Yapay zeka uygulamaları her alanda olduğu gibi eğitim alanında da kullanılmaktadır. Yükseköğretimde yapay zeka; analitikler, robot yazarlar, sanal deneyimler ve zeki öğretim sistemleri gibi yenilikçi sistemlerin temelini oluşturmaktadır (Riedel vd., 2017). Yapay zeka alanındaki ilerlemeler yükseköğretim kurumlarının yönetim süreçlerini ve iç mimarisini temelden değiştirme potansiyeli ile öğretme ve öğrenme sürecine yönelik yeni olasılıklar sunma potansiyeline sahiptir (Popenici ve Kerr, 2017).

Zawacki-Richter vd. (2019) tarafından gerçekleştirilen eğitim alanındaki yapay zeka uygulamalarının incelendiği çalışmada, bu uygulamalar 4 boyutta sınıflandırılmıştır:

- Profil oluşturma ve tahmin (giriş koşullarına yönelik kararlar ve ders planlaması, öğrenenlerin sistemden ayrılmaları ve sistemde tutulmaları, öğrenen modelleri ve akademik başarı ile ilgili çalışmalar)
- Zeki öğretim sistemleri (ders içeriğinin öğretimi, güçlü yönlerin belirlenmesi ve otomatik geri bildirim, öğrenme malzemelerini düzenlemek, işbirliğini kolaylaştırmak ve öğretmenlerin bakış açılarına yönelik çalışmalar)
- Ölçme ve değerlendirme (otomatik notlandırma, geri bildirim, öğrenen anlayışının değerlendirilmesi, katılım ve akademik doğruluk ve öğretimin değerlendirilmesi ile ilgili çalışmalar)
- Uyarlanabilir sistemler ve kişiselleştirme (ders içeriğini öğretmek, içeriklere yönelik kişiselleştirilmiş öneriler sunmak, öğretmenleri ve öğrenme tasarımını desteklemek, öğrenenleri izlemek ve yönlendirmek için akademik verileri kullanmak, kavram haritalarında bilginin sunulmasına yönelik çalışmalar)

Yapay zeka, makine öğrenmesi ve derin öğrenme ile yakından ilişkilidir. Yapay zeka, makineler tarafından sergilenen insan zekası, makine öğrenmesi yapay zeka uygulamaları

geliřtirmek için kullanılan bir yaklařım, derin öğrenme ise makine öğrenmesinin uygulanması için bir teknik olarak deęerlendirilebilir (Copeland, 2016). Bu bağlamda, makine öğrenmesi ve derin öğrenmenin yapay zekanın alt dalları olduęu ve gelişim süreçlerinin birbirleriyle bağlantılı olarak devam ettięi söylenebilir (Görsel 1.3).



Görsel 1.3. Yapay zeka, makine öğrenmesi ve derin öğrenme iliřkisi (Copeland, 2016)

Makine öğrenmesi, yapay zeka uygulamalarının geliştirilmesinde önemli bir rol oynamaktadır. Makine öğrenmesi, insanların öğrenme řeklini taklit etmek için veri ve algoritmaların kullanımına odaklanmaktadır (IBM, 2021c). Makine öğrenmesinde algoritmalar sınıflama ve tahmin yapmak için eğitilmekte ve bu içgörüler karar verme sürecini yönlendirmek amacıyla kullanılmaktadır (IBM, 2021c). Makine öğrenmesi yöntemleri gözetimli (supervised), gözetimsiz (unsupervised), yarı gözetimli (semi-supervised) ve pekiřtirmeli (reinforcement) öğrenme olarak 4 grupta incelenebilir (Kang ve Jameson, 2018):

- Gözetimli Makine Öğrenmesi: Gözetimli makine öğrenmesinde verileri sınıflandırmak ya da sonuçları tahmin etmek için etiketlenmiş veri kümeleri kullanılmaktadır (IBM, 2021c). Gözetimli makine öğrenmesi sürecinde eğitim, test ve doğrulama veri setleri ile modeller eğitilmekte, test edilmekte ve

doğrulukları değerlendirilmektedir. Gözetimli makine öğrenmesinde problemlerin çözümünde sınıflama ve regresyon yöntemleri kullanılmaktadır.

- Gözetimsiz Makine Öğrenmesi: Gözetimsiz makine öğrenmesinde veriler içerisinde doğal olarak var olan kümelerin ve ilişkilerin belirlenmesi için etiketsiz veriler kullanılmaktadır. Gözetimsiz makine öğrenmesinde problemlerin çözümünde kümeleme, birliktelik ve ilişki analizi ve boyut azaltma yöntemleri kullanılmaktadır.
- Yarı Gözetimli Makine Öğrenmesi: Bu öğrenme türünde hem etiketli hem etiketsiz veriler var olduğunda bilgisayarların nasıl öğrenebileceği ile ilgilenilmektedir (Zhu ve Goldberg, 2009). Yarı gözetimli makine öğrenmesinde etiketli ve etiketsiz verilerin birleştirilmesinin öğrenme davranışını nasıl değiştirebileceğinin anlaşılması ve böyle bir kombinasyondan yararlanan algoritmaların tasarlanması amaçlanmaktadır (Zhu ve Goldberg, 2009). Bu öğrenme yöntemi, gözetimli bir öğrenme algoritmasının eğitimi için yeterli miktarda etiketlenmiş veri olmadığı durumlarda da kullanılabilir (IBM, 2021c).
- Pekiştirmeli Makine Öğrenmesi: Bu öğrenme türü, istenen davranış örneklerinin bulunmadığı ancak bazı performans kriterlerine göre davranış örneklerinin puanlanabildiği durumlarda kullanılmaktadır (Barto ve Dietterich, 2004).

Makine öğrenmesinde, bir uzmanın algoritma içindeki özelliklerin hiyerarşisini belirlemesi gerekirken, derin öğrenme işleminin bu yönünü otomatikleştirmektedir (IBM, 2021b). Derin öğrenme, birden çok işleme katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyiyle verilerin temsillerini öğrenmesine olanak tanımaktadır (LeCun vd., 2015). Derin öğrenme, büyük verideki örüntüleri öğrenmek için bilgi işlem gücündeki ilerlemeleri ve özel sinir ağları türlerini birleştirmektedir (SAS, 2021a). Sinir ağları, nöronlardan oluşmaktadır. Derin sinir ağları girdi katmanı, gizli katmanlar ve çıktı katmanından oluşmaktadır. Girdi katmanında, veri setinden seçilen veriler yer almaktadır. Gizli katmanlarda girdiler üzerinde problem durumuna bağlı olarak hesaplamalar

yapılmaktadır. Çıktı katmanında ise problemin çözümü döndürülmektedir. Sinir ağları ileri beslemeli ya da çok katmanlı algılayıcılar (MLPs), evrişimli sinir ağları (CNNs) ve tekrarlayan sinir ağları olarak sınıflandırabilir.

1.4. Sorun

Kurumlar ve kendi dersini tasarlayan öğretmenler açısından öğrenenlerin çevrimiçi öğrenme ortamlarındaki öğrenme süreci hakkında bilgi sahibi olmak önemlidir (Hung ve Crooks, 2009). Ancak öğretmen ve öğrenenlerin fiziksel olarak farklı ortamlarda bulunduğu açık ve uzaktan öğrenme uygulamalarında öğrenme davranışlarının gözlenmesi ve öğrenme süreçlerinin takibi zordur. Ancak açık ve uzaktan öğrenme uygulamalarında, çevrimiçi öğrenme ortamları ve öğrenme yönetim sistemi gibi öğrenme platformlarının kullanılması sürecin takibini olanaklı hale getirmiştir (Macfadyen ve Dawson, 2010).

Çevrimiçi öğrenme ortamlarında sunucu günlükleri aracılığıyla öğrenenlerin yaptıkları tüm hareketler kayıt altına alınmaktadır. Bu kayıtlardan elde edilen dijital ayak izleri öğrenme sürecine yönelik yeni bilgilerin keşfedilmesine olanak sağlayabilir. Öğrenenlerin çevrimiçi öğrenme ortamlarındaki davranışlarının belirlenmesi için ders notları, konu anlatım videoları ve deneme sınavları gibi öğrenme malzemelerine ilişkin kullanım durumları analiz edilebilir (Mubarak vd., 2020). Gezinme davranışı, öğrenenlerin dersteki hareketlerini, hangi öğrenme nesnelere eriştiklerini ve hangi sırayla öğrenme malzemelerini kullandıklarını ifade etmektedir (Graf vd., 2010). Bu bağlamda, öğrenenlerin çalışma alışkanlıklarını ve nasıl öğrendiklerini anlamak için öğrenenlerin öğrenme malzemeleri kullanım örüntüleri belirlenebilir (Hung ve Crooks, 2009). Öğrenme malzemeleri kullanım örüntüleri ile öğrenenlerin içeriklere olan ilgisi ve içerik kullanım tercihleri ortaya çıkarılabilir (Cruz-Benito vd., 2015). Bu bilgi; kurum, öğretmen ve öğrenenler açısından öğrenme sürecinin dijitalleştirilmesi ve böylece sürecin gözlemlenebilmesi açısından önemlidir. Öğrenenlerin çevrimiçi öğrenme ortamlarındaki hareketleri ve öğrenme malzemeleri kullanım örüntüleri tanımlandığında öğrenen ihtiyaçlarına uygun olarak öğretim tasarımı ve içerik geliştirme süreçleri kurgulanabilir. Bu da öğrenenlerin sistemdeki etkileşim oranının artmasına destek olabilir.

Açık ve uzaktan öğrenme kurumlarında bilgi ve iletişim teknolojilerinin sunduğu olanaklarla birlikte öğrenen sayıları ve buna paralel olarak öğrenen kitlesinin heterojenliği de artmıştır (Bates, 2015; Moore ve Kearsley, 2011; Simonson vd., 2012). Farklı demografik özelliklere, geçmiş öğrenme yaşantılarına, beklentilere, gereksinimlere ve ilgilere sahip olan uzaktan öğrenenler pek çok açıdan birbirinden farklılaşmaktadır. Bu farklılaşma kurumların öğrenme süreçleri, öğrenme ortamları ve destek hizmetleri gibi pek çok bileşenle ilgili doğru ve hızlı kararlar vermelerini zorlaştırmaktadır. Öğrenen özelliklerinde artan çeşitlilik, öğrenme ortamlarının tasarlanmasından destek hizmetlerinin planlanmasına kadar her alanda öğrenenlerin gereksinimlerine uygun olarak kurumların yapılarını güncellemelerini gerektirmektedir (Stöter vd., 2014). Akademik karar verme süreçlerinin desteklenmesi, öğrenen merkezli öğretimin gerçekleştirilebilmesi, gereksinim tabanlı hizmetlerin sunulabilmesi, kişiselleştirilmiş ve uyarlanabilir öğrenme ortamlarının geliştirilebilmesi için öğrenme davranışlarının belirlenmesi ve öğrenen profillerinin ortaya çıkarılması önemlidir (Bates, 2015; Graf ve Kinshuk, 2013; Stöter vd., 2014).

Öğrenmeyi en üst düzeye çıkarmak için, öğrenenlerin tüm yönleriyle derinlemesine tanınması gerekmektedir (Powell ve Kusuma-Powell, 2011). Öğrenen özelliklerinin ve öğrenme davranışlarının analiz edilmesi, öğrenenlerin öğrenme tercihlerinin, zorlandıkları alanların ve güçlü yönlerinin belirlenmesinde kullanılabilir (Vellido vd., 2011). Öğrenenlerin öğrenme davranışlarının ve öğrenen özelliklerinin belirlenmesi, tanımlayıcı analitikler kapsamında değerlendirilebilir. Öğrenen davranışlarının ve özelliklerinin belirlenmesi için makine öğrenmesi algoritmaları ile elde edilen modeller kullanılabilir. Alanyazında, çalışmalarda model geliştirilirken farklı algoritmaların test edilmesi ve sonuçların çalışma bağlamı kapsamında değerlendirilmesi ve yorumlanmasının önemli olduğu belirtilmektedir.

Açık ve uzaktan öğrenme sistemlerinde kayıtlı öğrenen sayılarındaki dikkat çeken artışın yanında sistemden ayrılma oranlarının da yükseldiği bilinmektedir (Bawa, 2016; Lee ve Choi, 2011). Öğretim programlarını başarıyla tamamlamadan sistemden ayrılma, açık ve uzaktan eğitim kurumları için ciddi bir problemdir (Mubarak vd., 2020; Lee ve Choi, 2011; Wang vd., 2019). Bu durumun öğrenen performansları, çevrimiçi öğrenme sistemi ile etkileşim ve süreç boyunca öğrenen devamlılığının sürdürülebilmesi ile de ilgili olduğu söylenebilir. Bu sorunun olası çözümleri arasında öğrenen davranışlarının çözümlenmesi,

risk durumundaki öğrenenlerin belirlenmesi ve erken müdahale uygulamalarının gerçekleştirilmesi sayılabilir (Mubarak vd., 2020).

Dijital çağdaki teknolojik olanaklarla kurumların kendi yapılarına uygun olarak geliştirdikleri tahmin modelleri kullanılarak öğrenenlerin performans durumları ilk haftalardan itibaren tahmin edilebilmektedir (Hu vd., 2014; Milne vd., 2012). Bu tahminlere dayalı olarak öğrenenlerin sistemde devam etmelerine yönelik erken müdahale planları tasarlanabilir. Aynı zamanda yapay zeka ve öğrenme analitiği uygulamaları ile erken müdahale uygulaması olarak kişiselleştirilmiş geri bildirimler öğrenenlere sunulabilir ve motivasyonlarının artmasına destek olunmasıyla sistemden ayrılma oranları azaltılabilir (Karaoglan Yılmaz ve Yılmaz, 2021).

Açık ve uzaktan öğrenme sistemlerinde öğrenme analitikleri ile tanımlayıcı ve tahmin edici çalışmaların gerçekleştirilmesi kadar bu çalışmalardan elde edilen bilgiler ışığında eyleme yönelik uygulamaların gerçekleştirilmesi de önemlidir (Khalil ve Ebner, 2015). Öğrenme analitikleri ile yöneticiler ve öğretmenlere bilgi sunulmasının yanı sıra öğrenenlerin de kendi öğrenme süreçleri hakkında farkındalık kazanmalarına ve eyleme geçmelerine olanak sağlayacak uygulamalar tasarlanmalıdır. Bunun için öğrenenlerin hem ilerleme durumları hakkında bilgi sahibi olmalarına hem de bu bilgilerden yararlanarak eyleme geçebilmelerine olanak sağlayan PDP'ler kullanılabilir (Kemsley, 2020; Knight vd., 2015).

PDP'ler kişiselleştirilmiş geri bildirim mesajları ile öğrenme sürecini öğrenenler için görünür hale getirerek öğrenme süreçlerini desteklemek için kullanılmaktadır (Kokoç ve Altun, 2019; Ulfa vd., 2019). Kişiselleştirilmiş geri bildirim mesajları gibi erken müdahaleler ile öğrenenlerin motivasyon, başarı ve derse devam etme oranlarının yükseldiği görülmüştür (Arnold ve Pistilli, 2012; Sclater vd., 2016).

Bu çalışma, Anadolu Üniversitesi Açıköğretim Sisteminde Anadolium eKampüs öğrenme yönetim sistemini kullanan öğrenenler ile gerçekleştirilmiştir. Anadolu Üniversitesi Açıköğretim Sistemi, 2020-2021 eğitim-öğretim yılında kayıtlı 3 milyondan fazla öğrenen sayısı ile Türkiye'de yükseköğretimdeki öğrenenlerin neredeyse yarısına eğitim hizmeti sunmuştur (YÖK, 2021). Dolayısıyla bu sistemde gerçekleştirilecek çalışmaların Türkiye'deki yükseköğretime katkı sunacağı ön görülmektedir. Anadolium eKampüs öğrenme yönetim sistemi ile öğrenenlerin öğrenme sürecindeki davranışlarına yönelik tüm veriler kayıt altına alınmaktadır. Bu bağlamda gerçekleştirilen bu çalışmada, Anadolu

Üniversitesi Açıköğretim Sisteminde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin belirlenmesi ve öğrenen profillerinin oluşturulması, öğrenenlerin bir dersteki akademik performanslarına yönelik tahmin modelinin geliştirilmesi, öğrenme yönetim sistemine entegre olarak çalışabilen PDP'nin geliştirilmesi ve öğrenme sürecindeki etkilerinin incelenmesi hedeflenmektedir. Öğrenme analitikleri alanındaki çalışmalar incelendiğinde daha kapsamlı analizler için veri eksikliği yaşandığı, farklı veri kaynaklarından elde edilen verilerin kullanılması ile daha anlamlı ve genellenebilir sonuçların ortaya çıkabileceği değerlendirilmektedir (Amershi ve Conati, 2009; Jovanovic vd., 2012; Yukselturk ve Top, 2013). Bunun yanı sıra, genelleştirilebilir ve aktarılabilir bulgular üretmek için büyük ölçekli, boylamsal ve deneysel araştırmalara odaklanılması gerektiği ifade edilmektedir (Ifenthaler ve Yau, 2020). Bu çalışma, büyük bir öğrenen kitlesine ait veriler ile gerçekleştirildiğinden alanyazına katkı sunacağı düşünülmektedir. Bunun yanı sıra çalışma tanımlayıcı, tahmin edici ve normatif analitik aşamalarının üçünü birlikte içermesi açısından alanyazındaki çalışmalardan farklılaşmaktadır. Çalışmanın son boyutunda deneysel tasarım ile PDP uygulaması gerçekleştirilmiştir. Bu bağlamda çalışmanın veri kaynakları, veri büyüklüğü ve yöntem açısından alanyazına katkı sunacağı düşünülmektedir.

1.5. Amaç

Bu araştırmanın genel amacı, kitlesel açık ve uzaktan öğrenme sisteminde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin ve öğrenen profillerinin belirlenmesi, akademik performanslarına yönelik tahmin modeli geliştirilmesi, öğrenme yönetim sistemine entegre olarak çalışabilen bir PDP'nin tasarlanması ve PDP'nin öğrenme sürecindeki etkilerinin incelenmesidir. Bu bağlamda çalışmada aşağıdaki sorulara yanıt aranmıştır:

1. Kitlesel açık ve uzaktan öğrenme sisteminde öğrenenlerin e-öğrenme ortamı kullanım davranışlarında hangi örüntüler bulunmaktadır?
2. Kitlesel açık ve uzaktan öğrenme sisteminde öğrenenlerin demografik özellikleri, e-öğrenme ortamı kullanım davranışları ve akademik performansları kullanılarak öğrenen profilleri oluşturulabilir mi?

- 2.1. Öğrenen profillerinin oluşturulmasında en ayırt edici değişkenler hangileridir?
- 2.2. Öğrenen profillerinin oluşturulması için kullanılacak en başarılı algoritmalar hangileridir?
3. Kitlesele açık ve uzaktan öğrenme sisteminde öğrenenlerin e-öğrenme ortamındaki etkileşimleri kullanarak öğrenenlerin akademik performansı tahmin edilebilir mi?
 - 3.1. Öğrenenlerin akademik performans tahmin modelinin oluşturulmasında en yüksek tahmin gücüne sahip değişkenler hangileridir?
 - 3.2. Öğrenenlerin akademik performansının tahmin edilmesi için doğruluk oranı en yüksek algoritmalar hangileridir?
4. Kitlesele açık ve uzaktan öğrenme sistemlerinde PDP kullanımının öğrenme sürecine etkileri nelerdir?
 - 4.1. Deney ve kontrol gruplarının ÖYS’de oturum açma sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
 - 4.2. Deney ve kontrol gruplarının ÖYS’de oturum açtıkları gün sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
 - 4.3. Deney ve kontrol gruplarının öğrenme malzemelerine erişim sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
 - 4.4. Deney ve kontrol gruplarının akademik performanslarında istatistiksel olarak anlamlı bir farklılık var mıdır?
5. PDP kullanımına yönelik öğrenenlerin görüşleri ve memnuniyet düzeyleri nasıldır?

Çalışma kapsamında, öğrenenlerin Öğrenci Bilgi Sistemi ve Öğrenme Yönetim Sistemi veritabanlarında yer alan verileri analiz edilerek 5 temel ve 8 alt araştırma sorusuna yanıt aranmıştır.

1.6. Önem

Bu çalışmada Anadolu Üniversitesi Açıköğretim Sistemi'nde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin ve profillerin belirlenmesi, akademik performanslarına yönelik tahmin modeli geliştirilmesi, ÖYS'ye entegre olarak çalışabilen PDP tasarımı ve PDP'nin öğrenme sürecindeki etkilerinin incelenmesi hedeflenmiştir. Bu yönüyle çalışma, farklı özelliklerdeki öğrenenlerden oluşan ve büyük bir öğrenen kitlesine sahip olan Anadolu Üniversitesi Açıköğretim Sisteminde yer alan öğrenenlerin derinlemesine tanınmasına sunacağı katkı açısından önemlidir.

Öğrenenlerin çevrimiçi öğrenme ortamındaki davranışlarının belirlenmesi, öğrenenlerin öğrenme süreçleri hakkında bilgi edinmesine katkı sağlayabilir. Bu katkı; içeriklerin kullanımı hakkında bilgi edinilmesine, tasarlanacak yeni içerik türlerine yön gösterilmesine, öğretim tasarımının değerlendirilmesine ve öneri sistemlerinin geliştirilmesine olanak sağlaması açısından önemlidir. Bu, hem öğrenenler için hem de kurum için faydalı bir bilgi olabilir. Öğrenenler çalışma alışkanlıkları hakkında detaylı olarak bilgi sahibi olabilir ve çalışma süreçlerini buna göre planlayabilirler. Kurumlar ise veri analizi ile elde edilen bulgulardan yararlanarak veriye dayalı olarak karar verme süreçlerini güçlendirebilirler.

Öğrenen özelliklerinin ve öğrenme davranışlarının belirlenmesi, öğrenenlerin öğrenme tercihlerinin, zorlandıkları alanların ve güçlü yönlerinin belirlenmesinde kullanılabilir. Öğrenen profillerinin belirlenmesiyle farklı profillere sahip öğrenen gruplarına özel öneriler sunulabilir. Risk durumundaki öğrenenler gerçek zamanlı olarak belirlenebilir ve önlem planları geliştirilerek farklı iletişim kanalları oluşturulabilir. Sistemde doğal olarak var olan gruplar keşfedilerek öğrenenlerin tamamına aynı hizmetleri sunmak yerine özelleştirilmiş ve uyarlanmış hizmetler verilebilir.

Açık ve uzaktan öğrenme sistemleri, öğrenenler tarafından esnek yapısı ve sunduğu olanaklar nedeniyle sıklıkla tercih edilmekte ve bu sistemlerde yüksek sayıda öğrenene hizmet verilmektedir. Açık ve uzaktan öğrenme kurumlarındaki yüksek öğrenen sayılarına rağmen sistemden mezun sayısının az, ayrılma oranının ise yüksek olduğu bilinmektedir (Willging ve Johnson, 2009). Açıköğretim Sistemi özelinde bakıldığında; 2021-2022 öğretim yılı Güz döneminde 1.158.045 aktif, 1.242.404 pasif öğrenen bulunmaktadır (Anadolu

Üniversitesi, 2021). Sistemdeki öğrenenlerin pasif durumda olup kayıt yenilememeleri ya da tamamen sistemden ayrılmaları problemi, tüm paydaşlar açısından zaman, emek ve para kaybına neden olmaktadır. Bu çalışma kapsamında, öğrenen tahmin modelinin geliştirilmesiyle başarısız olacak ya da sistemden ayrılacak öğrenenlerin önceden belirlenmesi ve erken önlemlerin uygulanmasıyla sistemden ayrılma oranları azaltılabilir ve başarı oranları yükseltilebilir.

Aidiyet ihtiyacı, tüm eğitim ortamlarında en önemli ihtiyaçlardan biridir (Jackson vd., 2010). Ders sorumlusu ve öğrenen arasındaki etkileşimler, kaygıyı azaltarak öğrenenlerin fikirlerini geliştirmelerine ve bağlantılar kurmalarına yardımcı olmaktadır (Peacock vd., 2020). Bunun yanı sıra, öğrenenlerin öğrenme deneyimlerinde aidiyet duygusu oluşturan öğretmenleri daha fazla önemsedikleri ve bu durumun öğrenenlerin derste devam etmelerine destek olduğu belirlenmiştir (Peacock vd., 2020). Bu çalışma kapsamında geliştirilen PDP ile öğrenenlerin ilerleme durumlarının görselleştirilmesi ve ders sorumlusu tarafından öğrenenlere özgü kişiselleştirilmiş geri bildirim mesajlarının gönderilmesi ile öğrenenlerin açık ve öğrenme ortamlarında yalnız hissetmeleri önlenebilir ve aidiyetleri artırılabilir. Aynı zamanda bu durum, öğrenenlerin sistemle ve öğrenme malzemeleriyle etkileşimlerini arttırmaya olanak sağlaması açısından da önemlidir.

Bu çalışma, veri analitiğinin aşamalarından tanımlayıcı, tahmin edici ve normatif analitik aşamalarının üçünü birlikte kapsamakta olup bu yönüyle alandaki çalışmalardan farklılaşmaktadır. Alanyazında tanımlayıcı ve tahmin edici çalışmalar olmakla birlikte, bu çalışmalar çoğunlukla yüz yüze ve uzaktan öğrenmenin birlikte yürütüldüğü harmanlanmış öğrenme ortamlarında gerçekleştirilmiştir. Açıköğretim Sistemi gibi kitlesel boyutta tamamen uzaktan eğitim veren kurumlar üzerinde gerçekleştirilen çalışmalarda ise kitlesel boyuttaki çalışmalar oldukça azdır. Bunlara ek olarak, bu çalışmada öğrenme analitikleri ve yapay zeka yöntemleri birlikte kullanılarak modeller geliştirilmiştir. Bu çalışma sonucunda elde edilen yapay zeka tabanlı modellerin öğrenme yönetim sistemine entegre edilmesiyle bu modeller, öğrenme yönetim sistemlerinde insan müdahalesine gerek kalmadan otomatikleştirilmiş olarak kullanılabilirler. Sunulan bu gerekçelerle gerçekleştirilen çalışmanın diğer e-öğrenme ortamlarında da öğrenme analitiklerinin verimlilik amaçlı kullanımına yönelik bir yol haritası sunarak uzaktan eğitim bilim alanına metodolojik açıdan da özgün katkılar sağlayacağı düşünülmektedir.

1.7. Sınırlılıklar

Bu araştırma çeşitli sınırlılıklar dahilinde planlanmış ve gerçekleştirilmiştir. Çalışma, Anadolu Üniversitesi Açıköğretim Sisteminde kayıtlı olan ve Anadolium eKampüs'ü kullanan öğrenenlere ait veriler kullanılarak gerçekleştirilmiştir. Çalışma araştırma soruları bağlamında 3 aşama olarak planlanmıştır. Tanımlayıcı analitik aşaması öğrenme davranışlarındaki örüntülerin ve öğrenen profillerinin belirlenmesinden oluşmaktadır. Tahmin edici analitik aşaması öğrenen performansının tahmin edilmesi, normatif analitik aşaması ise PDP'nin uygulanması ve PDP'ye yönelik öğrenen görüşlerine yönelik anket çalışmasından oluşmaktadır. Çalışma tanımlayıcı, tahmin edici ve normatif analitik aşamalarından oluşmakta ve tanılayıcı analitik aşamasını içermemektedir. Bu bağlamda her aşamada farklı çalışma grupları ile analizler gerçekleştirilmiştir. Çalışma grupları aşağıda açıklanmıştır:

1. Çevrimiçi öğrenme ortamında öğrenen davranış örüntülerinin belirlenmesi çalışması, 2019-2020 öğretim yılı Güz döneminde Açıköğretim Sistemine kayıtlı olan 602.372 öğrenen ile sınırlıdır.
2. Öğrenen profillerinin belirlenmesi çalışması, 2019-2020 öğretim yılı Güz döneminde Açıköğretim Sistemine kayıtlı olan 597.164 öğrenen ile sınırlıdır.
3. Akademik performans tahmin modelinin geliştirilmesi çalışması, 2019-2020 öğretim yılı Güz döneminde BIL101U dersine kayıtlı olan 56.810 öğrenen ile sınırlıdır.
4. PDP uygulaması çalışması, 2020-2021 öğretim yılı Bahar döneminde BIL102U dersine kayıtlı olan 26.753 öğrenen ile sınırlıdır. Bu süreçte öğrenenler, deney ve kontrol grubu olarak 2 gruba ayrılmıştır. Deney grubundaki öğrenenlere PDP uygulaması sunulmuş, kontrol grubundaki öğrenenlere ise sunulmamıştır. Deney grubu 13.377, kontrol grubu 13.376 öğrenen ile sınırlıdır.
5. PDP'ye yönelik öğrenen görüşlerinin belirlenmesi çalışması, 2020-2021 öğretim yılı Bahar dönemi sonunda BIL102U dersinde deney grubunda yer alan öğrenenlerden anketi gönüllü olarak yanıtlayan 451 öğrenen ile sınırlıdır.

Bu çalışma sonucunda elde edilen modeller; belirtilen yıl, dönem, çalışmaya katılan öğrenenler ve çalışmada yer alan dersler ile sınırlıdır. AÖS'te öğrenenlerin öğrenme yönetim sistemini kullanmaları zorunlu değildir. Öğrenenler öğrenme malzemelerini indirdikten sonra çevrimdışı olarak da çalışmalarına devam edebilirler. Öğrenenlerin çevrimdışı öğrenme süreçlerine yönelik veri bulunmadığından dolayı çalışmada öğrenenlerin öğrenme yönetim sistemi üzerindeki hareketleri değerlendirilmiştir. Çalışmada öğrenme malzemesine erişen öğrenenlerin bu öğrenme malzemelerini öğrenme süreçlerinde kullandıkları kabul edilmiştir. Anadolium eKampüs Sisteminde oturum açık kaldığı sürece öğrenenlerin öğrenme etkinlikleri gerçekleştirdikleri varsayılmıştır. Ayrıca sorularla öğrenelim ve çözümlü sorular malzemelerine ait verilerde sorun olduğu belirlenmiş ve bu veriler analizlere dahil edilmemiştir. Çalışma aşamaları birbirini takip eden dönemlerde gerçekleştirilmek üzere planlanmıştır. Ancak COVID-19 dönemi nedeniyle öğrenenlerin sistem kullanımlarındaki değişim göz önüne alınarak tahmin modeli planlanan dönemde gerçekleştirilememiştir. COVID-19 döneminde sınav uygulama yönteminde de değişiklik olmuştur. AÖS'te sınavlar gözetimli bir şekilde yüz yüze olarak 2 günde yapılmakla birlikte COVID-19 döneminde çevrimiçi olarak ortalama 2 haftada gerçekleştirilmiştir. Bu dönemde öğrenenlerin sınav puanlarında da farklılaşmalar olduğu belirlenmiştir. Bu nedenle çalışma planlanan süreçten farklı bir şekilde sürdürülmüş ve bu durum aşamaların bütüncül bir şekilde devam etmesine engel olmuştur. Çalışmada akademik performansın belirlenmesinde 2019-2020 öğretim yılı Güz döneminde BIL101U dersine kayıtlı olan öğrenenlerin dönem sonu harf notları kullanılmıştır. Bu amaçla 11 farklı harf notu gruplanarak 5 harf notu grubu elde edilmiş ve performans tahmini üretilen yeni harf notlarına göre gerçekleştirilmiştir. BIL101U dersi genellikle 1. sınıftaki öğrenenler tarafından ilk dönemde alınmaktadır. Bu nedenle bu öğrenenlerin genel not ortalamaları henüz hesaplanmamıştır. Öğrenenlerin genel not ortalamalarının tahmin modelinde önemli olabileceği düşünülmeyle birlikte açıklanan nedenlerden dolayı tahmin modelinde girdi olarak yer almamıştır. Tahmin modeli sonuçları farklı dönemdeki veri setleri ile test edilemediği için 10 katlı çapraz doğrulama yapılarak modellerin doğruluğu değerlendirilmiştir. PDP'nin uygulanmasında deneysel bir tasarım gerçekleştirilmiş ve öğrenme ortamı kontrol altına alınmıştır. Çalışma kapsamında kontrol edilebilir öğrenme ortamları dışında kalan değişkenler göz ardı edilmiştir.

1.8. Tanımlar

Tanımlayıcı Analitik: Tanımlayıcı analitikte, mevcut durumun tanımlanması ve durum analizinin yapılması amaçlanmaktadır.

Tahmin Edici Analitik: Tahmin edici analitikte var olan veriler analiz edilmekte ve geleceğe yönelik tahminler ve öngörüler oluşturulmaktadır.

Normatif Analitik: Normatif analitikte var olan ya da gelecekte ortaya çıkması öngörülen durumlara ilişkin kurallar ve eylemler geliştirilmektedir.

Öğrenme Analitikleri: Öğrenme analitikleri ile öğrenenlerin öğrenme sürecine ilişkin verilerinin analiz edilerek öğrenme sürecinin iyileştirilmesi, bu veri analizine dayalı olarak uygulamaların ve eylemlerin gerçekleştirilmesi ve bunların raporlanması amaçlanmaktadır.

Gezinme Davranışı: Gezinme davranışı, öğrenenlerin öğrenme ortamındaki ayak izlerinden elde edilmektedir. Gezinme davranışlarının ortaya çıkarılması için öğrenenlerin bu ortamdaki hareketleri, öğrenme malzemelerine erişimleri ve ortamdaki bileşenleri kullanma durumları incelenmektedir.

Erişim (Etkileşim, Kullanım) Verileri: Bu veriler, öğrenme yönetim sistemindeki öğrenme malzemelerine erişimi göstermektedirler. Erişim verileri, öğrenme malzemesi türü, erişme zamanı ve erişim sayısından oluşmaktadır.

Öğrenen Profili: Öğrenenlerin demografik özellikleri, çevrimiçi öğrenme ortamındaki davranışları ve sınav puanları gibi verilerinin analiz edilmesiyle öğrenenlerin benzer özelliklerine göre gruplanması olarak ifade edilebilir.

Öğrenme Analitiklerine Dayalı Performans Değerlendirme Paneli: Öğrenme analitiklerine dayalı performans değerlendirme panelleri (PDP), çevrimiçi öğrenme ortamlarındaki öğrenme süreçleri ile ilgili farklı göstergelerin görselleştirilmesiyle öğrenenlere ilerleme durumları ve öğrenme davranışlarına ilişkin bilgilerin bütüncül olarak sunulmasına olanak sağlayan bir araçtır.

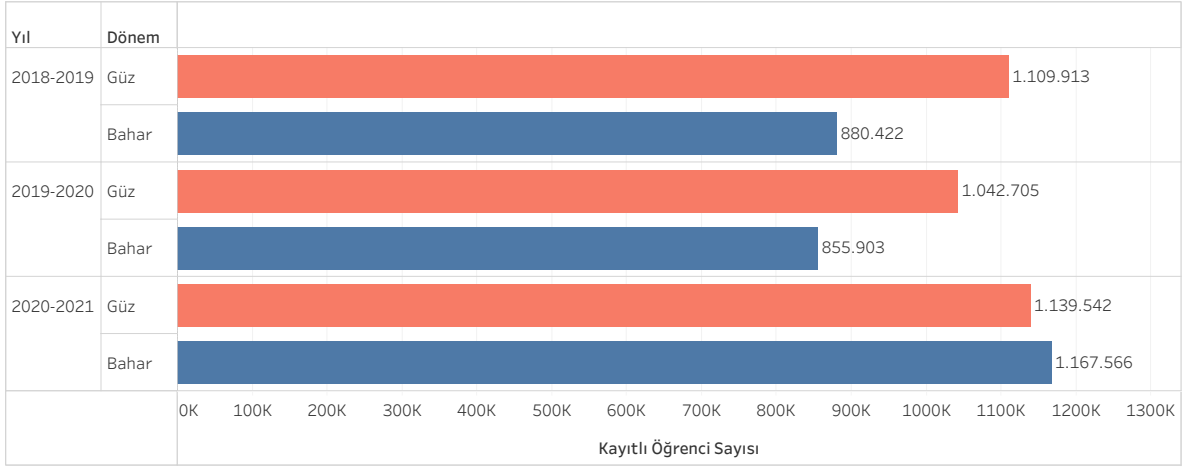
1.9. Arařtırma Baęlamı

Bu bölümde, alıřmanın gerekleřtirildięi Anadolu niversitesi Aıkğretim Sistemi, Anadolun eKamps ğrenme ynetim sisteminin zellikleri, bileřenleri, ğrenme malzemeleri ve kullanım oranları aıklanmıřtır.

1.9.1. Anadolu niversitesi Aıkğretim Sistemi

Anadolu niversitesi Aıkğretim Sistemi (AS), 1982 yılından bu yana uzaktan ğrenme hizmeti sunan bir mega niversitedir (Daniel, 1996). AS, yksekğretim sistemi baęlamında eęitimde fırsat eřitlięi ilkesini gerekleřtirmeyi amalamaktadır (A, 2021a). Bu baęlamda bu sistem ile Trkiye'deki ğrenenlerin yanı sıra yurtdıřındaki ğrenenlere de ğrenme hizmeti sunulmaktadır. AS; Aıkğretim, İřletme ve İktisat Fakltelerinden oluřmaktadır. 2021-2022 ğretim yılı Gz dneminde AS'te 43 nlisans ve 22 lisans programı bulunmaktadır (A, 2021b). AS yurt dıřı programları ile Kuzey Kıbrıs Trk Cumhuriyeti, Batı Avrupa lkeleri, Azerbaycan, Kosova, Makedonya ve Bulgaristan, Bosna Hersek ve Arnavutluk, Kuzey Amerika ve Arap Yarımadasındaki ğrenenlere ğrenme hizmeti sunulmaktadır (A, 2021c). Bunların yanı sıra AS, niversite ğrencilerine ve mezunlarına sınavsız olarak İkinci niversite fırsatı da sunmaktadır (A, 2021d).


AS, uzaktan eęitim teknolojilerini kendi ğrenme ortamlarına entegre eden ve ğrenen ihtiyalarını gz nne alarak yeni teknolojilerin ve uygulamaların ğrenme srecine dahil edilmesi zerinde alıřmalar yrten bir niversite olarak deęerlendirilebilir. AS, Trkiye'de yksekğrenim gren ğrenenlerin neredeyse yarısına ğrenme hizmeti sunmaktadır (YK, 2021). AS ğrenen sayıları yıllar bazında Őekil 1.1'de verilmiřtir.



Şekil 1.1. Yıl ve dönem bazında öğrenen sayıları

Şekil 1.1 incelendiğinde AÖS'te dönemlik öğrenen sayısının ortalama olarak 1 milyondan fazla olduğu söylenebilir. Buna ek olarak, 2020-2021 öğretim yılı hariç diğer yıllarda Güz döneminde öğrenen sayısının daha fazla olduğu görülmektedir.


Şekil 1.2'de AÖS'e kaydolun öğrenenler yaş grupları bağlamında değerlendirilmiştir.



Şekil 1.2. Yaş gruplarına göre yıl ve dönem bazlı öğrenen sayıları

Şekil 1.2 incelendiğinde, tüm dönemlerde öğrenenlerin büyük çoğunluğunu 26-33 yaş aralığındaki öğrenenlerin oluşturduğu değerlendirilmektedir. En az öğrenen sayısı ise öğretim yıllarının tamamında 42 yaş ve üstünde görülmektedir. AÖS'teki öğrenenlerin %50'den fazlasını 18-33 yaş aralığındaki öğrenenlerin oluşturduğu söylenebilir. 2020-2021 öğretim yılında ise 18-25 yaş arasındaki öğrenen oranının diğer yıllara göre arttığı görülmektedir.

Şekil 1.3'te AÖS öğrenen sayıları cinsiyetler bağlamında incelenmiştir. Şekil 1.3'te öğrenenlerin %50'den fazlasının erkek olduğu görülmekle birlikte kadın ve erkek öğrenen sayılarının birbirine yakın olduğu belirtilebilir.



Şekil 1.3. Cinsiyetlere göre yıl ve dönem bazlı öğrenen sayıları

1.9.2. Anadolu eKampüs öğrenme yönetim sistemi

Bu çalışma, Anadolu Üniversitesi Açıköğretim Sisteminde gerçekleştirilmiştir. Açıköğretim Sisteminde Anadolu eKampüs öğrenme yönetim sistemi kullanılmaktadır. Bu bölümde; Anadolu eKampüs'ün özellikleri ve bileşenleri, sistemde yer alan öğrenme kaynakları ve veritabanı yapısı ele alınmaktadır.

1.9.2.1. Özellikleri

Anadolu eKampüs, Anadolu Üniversitesi tarafından öğrenme hizmetlerinin öğrenen merkezli ve bütüncül bir yapıyla sunulduğu bir ÖYS'dir. Anadolu eKampüs, 2015-2016 öğretim yılı Bahar döneminden bu yana kullanılmaktadır. Anadolu eKampüs, kurum ve öğrenen özellikleri ve ihtiyaçları göz önüne alınarak Anadolu Üniversitesi bünyesinde geliştirilmiştir.

Anadolum eKampüs ile öğrenenlere derslerin ve içeriklerin tek bir yerden sunulması, öğrenen-öğrenen, öğrenen-öğreten ve öğrenen-içerik etkileşiminin üst düzeye çıkarılması ve öğrenenlerin motivasyonlarının artırılması hedeflenmektedir. eKampüs yüksek sayıda öğrenenin içeriklere erişebilmesi, canlı derslere katılabilmesi ve sosyal etkinliklerde yer alabilmesi amacıyla geliştirilmiş bir e-öğrenme ortamıdır. Öğrenenler eKampüs üzerinden kayıtlı oldukları derslerin öğrenme malzemelerine erişebilmekte, onları inceleyebilmekte, kendi cihazlarına malzemeleri indirebilmekte, tartışma forumları ve sohbet ortamlarında hem öğretmenler hem de diğer öğrenenlerle iletişim ve etkileşim kurabilmektedirler (Görsel 1.4).



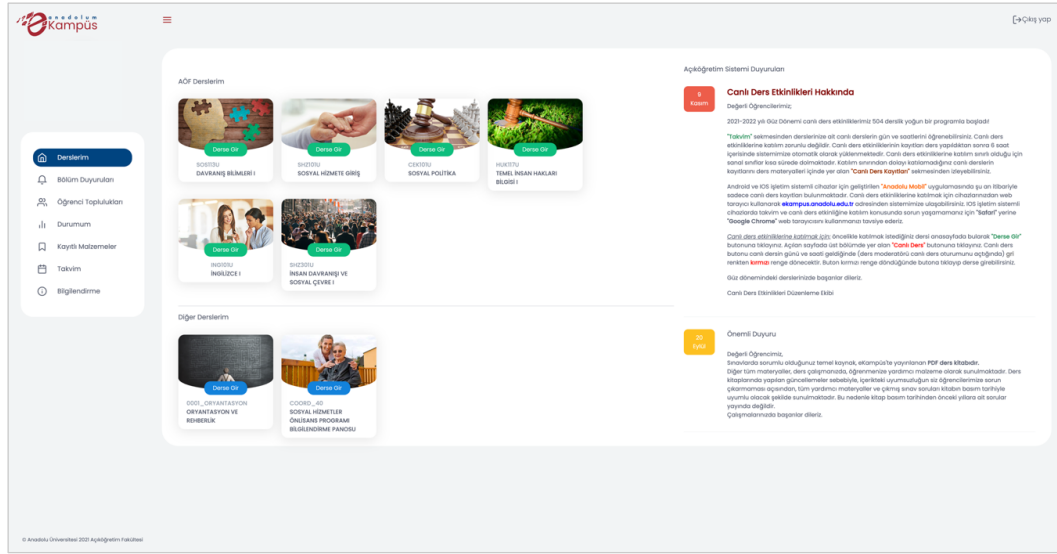
Görsel 1.4. Anadolum eKampüs giriş sayfası

Anadolum eKampüs, kurum bünyesinde farklı uygulamalarla işbirlikli olarak çalışabilecek şekilde geliştirilmiştir. Anadolum eKampüs'te yer alan öğrenme malzemelerinin takibi ve yönetimi, Envanter Takip Sistemi (ETS) üzerinden yapılmaktadır. ETS, PHP/Laravel tabanlı bir uygulamadır. Burada düzenlenen öğrenme malzemeleri otomatik olarak Anadolum eKampüs'te güncellenmektedir. Öğrenenler, Anadolum eKampüs'e <https://ekampus.anadolu.edu.tr> adresi üzerinden erişmektedirler. Öğrenenler, bu adrese kullanıcı adı ve şifreleri ile giriş yaparak kaydoldukları dersleri ve bu derslere ait öğrenme bileşenlerini görüntüleyebilmektedirler. Anadolum eKampüs, ön yüzü (front-end) React teknolojisi kullanılarak, arka yüz (back-end) servisleri ise Go programlama dili ile

yazılmıştır. Bu altyapı, Linux Ubuntu 16.04 işletim sistemine sahip makineler üzerinde çalışmaktadır.

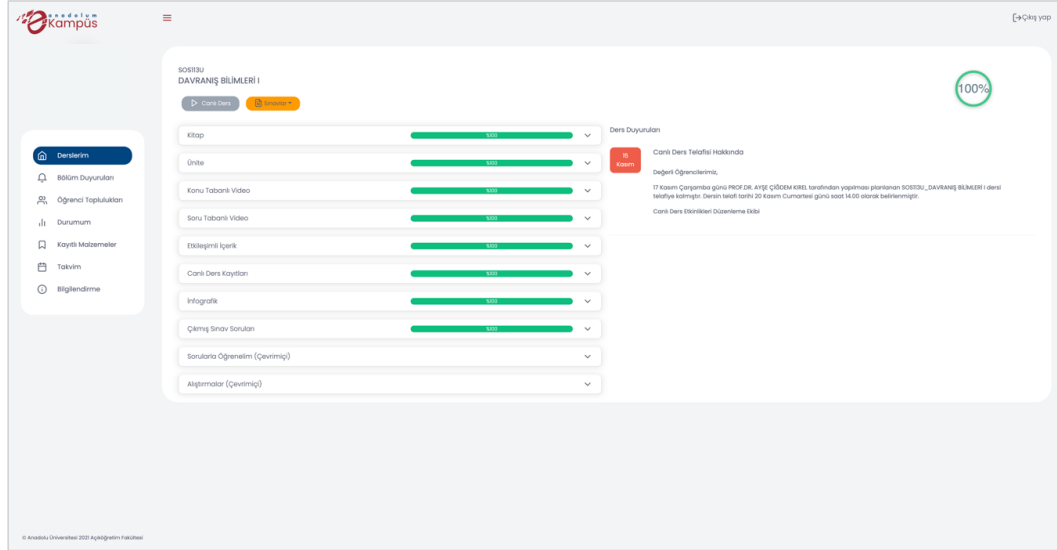
1.9.2.2. Bileşenler ve öğrenme malzemeleri

Anadolium eKampüs; Derslerim, Bölüm Duyuruları, Öğrenci Toplulukları, Durumum, Kayıtlı Malzemeler, Takvim ve Bilgilendirme bölümlerinden oluşmaktadır (Görsel 1.5).




Görsel 1.5. Anadolu eKampus anasayfası

Derslerim: Bu bölümde, öğrenenlerin kayıtlı oldukları dersler yer almaktadır. Öğrenenler “Derse Gir” butonuna tıklayarak ilgili dersin öğrenme malzemelerine erişebilirler. Derse giriş yapıldıktan sonra öğrenme malzemeleri, deneme sınavları ve ders ile ilgili duyurular görüntülenmektedir. Bunlara ek olarak, öğrenenlerin malzemelerin ne kadarını tamamladıklarını gösteren bir gösterge de bulunmaktadır (Görsel 1.6).



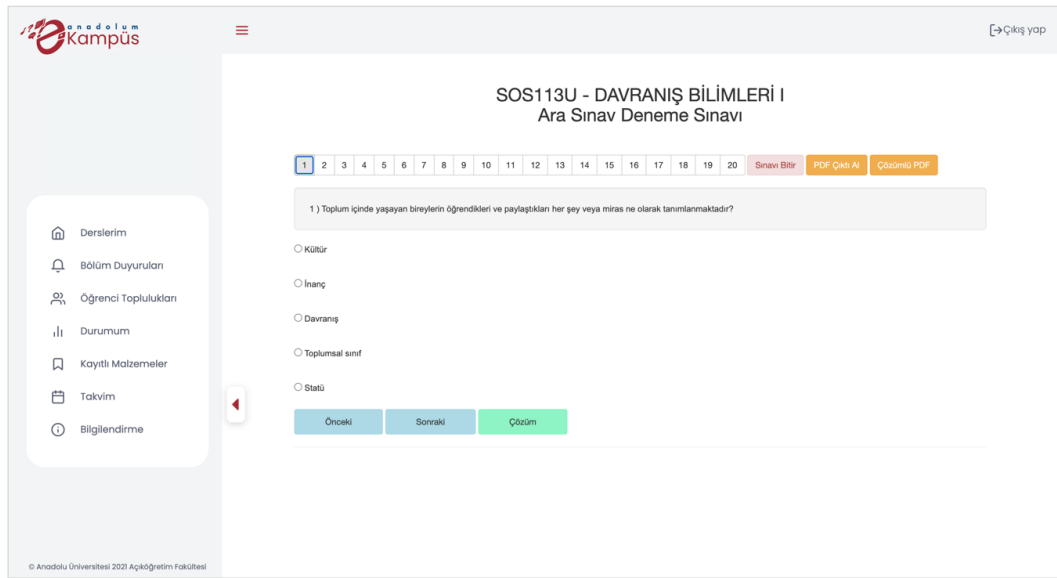
Görsel 1.6. Derslerim ekranı

Öğrenenler, canlı ders butonuna tıklayarak derslerine ait canlı derslere katılabilmektedirler. Canlı dersler, öğretim elemanları ve öğrenenlerin eş zamanlı olarak etkileşim kurmalarına olanak sağlayan sesli ve görüntülü konu anlatımı ve soru çözümünden oluşan öğrenme malzemeleridir. Sınavlar butonuna tıkladığında ise çevrimiçi olarak ara sınav ve dönem sonu sınavlarının örneklendiği deneme sınavlarına erişilmektedir (Görsel 1.7).



Görsel 1.7. Sınavlar sekmesi

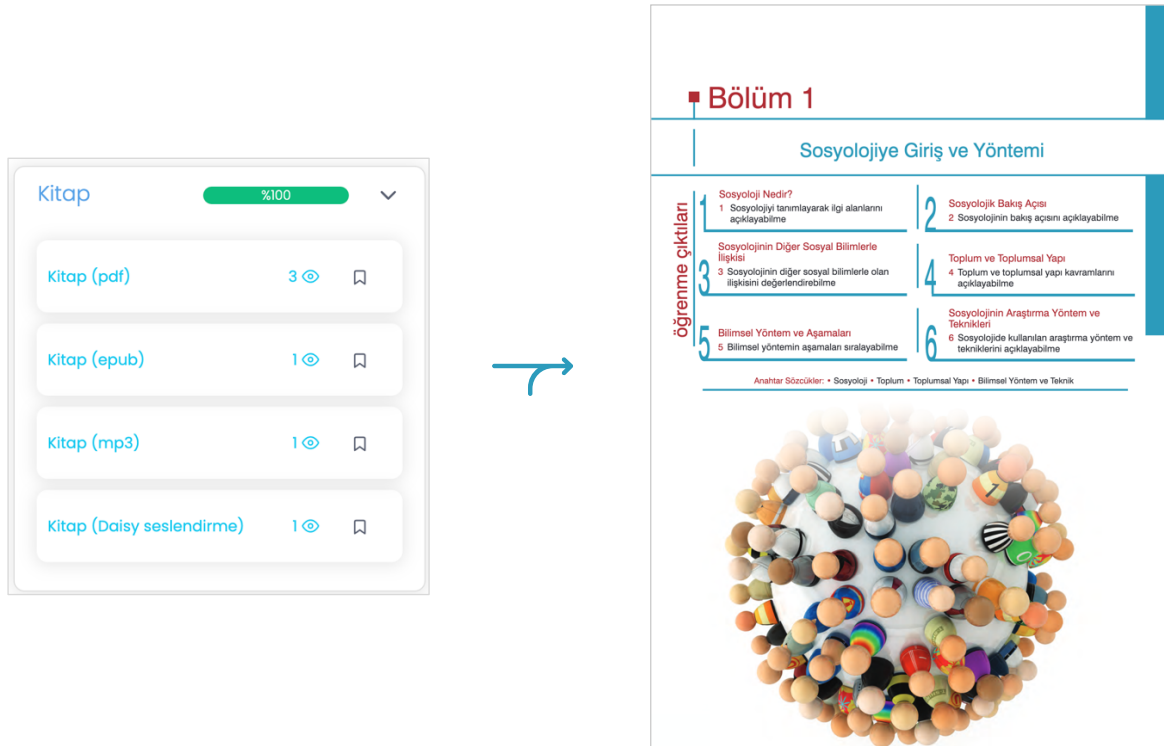
Deneme sınavları, sınav sorumluluk ünitelerini kapsayan çoktan seçmeli 20 sorudan ve yanıtlarından oluşmaktadır (Görsel 1.8). Öğrenenler, “Sınavı Bitir” butonuna tıklayarak sınav sonuçlarını öğrenebilirler. Sınav sonuçlarında öğrenenlerin aldıkları puan, doğru, yanlış ve boş soru sayıları ve sınavda geçirdikleri süre bilgisi kendilerine sunulmaktadır. Ayrıca öğrenenler, sınavlarını PDF ya da çözümlü PDF olarak kaydedebilirler. Öğrenenler, sınavı bitirdikten sonra “Yeni Sınav” butonuna tıklayarak ilgili derse yönelik farklı sınavlar oluşturup çözebilirler.



Görsel 1.8. Deneme sınavı ekranı

AÖS'te dersler ünite tabanlı olarak tasarlanmış olup öğrenenlere pdf türü, video türü, sesli ve etkileşimli malzemeler sunulmaktadır. Anadolu eKampüs'te öğrenme malzemeleri türlerine göre gruplandırılmıştır. Her malzeme türünün yanında öğrenenin malzemeyi tamamlama yüzdesi yer almaktadır. Bunun yanı sıra öğrenenlerin malzemeye kaç kere eriştikleri bilgisi ve malzemeyi Kayıtlı Malzemeler bölümüne ekleme butonu bulunmaktadır. Anadolu eKampüs'te yer alan öğrenme malzemeleri aşağıda açıklanmıştır:

Kitap: AÖS'te ders kitapları temel öğrenme malzemeleridir. Bu malzeme, ünite bazlı olarak alan uzmanları tarafından hazırlanmaktadır. Anadolu eKampüs'te kitaplar HTML, PDF, epub olarak farklı formatlarda öğrenenlere sunulmaktadır. Bunun yanı sıra sesli kitap olarak mp3 ve Daisy formatları da sistemde yer almaktadır (Görsel 1.9).



Görsel 1.9. Kitap örneği

Ünite: Bu bölümde Ünite (PDF), Ünite Özeti (PDF) ve Ünite Özeti (Sesli) öğrenme malzemeleri yer almaktadır (Görsel 1.10). Ünite (PDF), ders kitabının ünitelere bölünmüş halidir. Ünite Özeti ise her ünite için hazırlanan ünitelerin önemli noktalarının vurgulandığı ve özetlendiği, 2-4 sayfadan oluşan öğrenme malzemesidir. Ünite özetleri hem PDF hem de sesli formatta öğrenenlere sunulmaktadır.

Ünite		
Ünite Pdf	Ünite Özeti (PDF)	Ünite Özeti (Sesli)
Ünite 1	Ünite 1	Ünite 1
Ünite 2	Ünite 2	Ünite 2
Ünite 3	Ünite 3	Ünite 3
Ünite 4	Ünite 4	Ünite 4
Ünite 5	Ünite 5	Ünite 5
Ünite 6	Ünite 6	Ünite 6
Ünite 7	Ünite 7	Ünite 7
Ünite 8	Ünite 8	Ünite 8



SHZ101U-SOSYAL HİZMETE GİRİŞ

Ünite 1: Sosyal Çalışmanın Temel Kavramları

Bilim ve Meslek Dahil Olarak Sosyal Çalışma

Sosyal çalışmanın temel kavramları sosyal hizmet uygulamalarından ortaya çıkmış ve gelişmiştir. Sosyal çalışma, aynı zamanda çevresel bir meslek ve uygulama yönü olan bir disiplin dâhildir.

Sosyal çalışmanın ana kaynaklarına göre temel yaklaşımları şöyle sıralanabilir:

1. Sosyal çalışmayı kişinin sorunlarının çözülmesine yönelik bir meslek olarak ele alan tanımlar.
2. Sosyal çalışmayı sosyal refah alanına bağlı olarak ele alan tanımlar.
3. Sosyal çalışmayı bir toplumsal kurum olarak ele alan tanımlar.

V. Duman'a göre, sosyal hizmet bir dayanışma ve yardım etme mesleğidir, toplumsal hedef alır ve bilimsel ilke, yöntem ve teknikler aracılığıyla insanlara hizmet etmeyi amaçlar.

Demokratik değerlere ve katılımcı ilkelere sahip bir meslek olarak sosyal çalışma, geniş bir kavramsal alana sahiptir. "toplamsal çözümleri yaklaşımlar ve yöntemler içindeki kişi, grup ve toplumların sorunlarını önlemek ve refahını sağlamakla ilgilidir".

Sosyal çalışma, Amerikan Ulusal Sosyal Çalışmacılar Derneği'ne göre ise "Birey, grup ve toplumlara sosyal işlevselliğini geliştirebilecekleri kapasitelerini geliştiren ve bu amaçla görevlerini yerine getirecek toplumsal koşulları yaratma mesleki bir faaliyettir".

Sosyal çalışmanın nitelikleri ise şöyle sıralanabilir:

- Sosyal bir bilim dâhildir.
- Çoklu sosyal bilimlerden yararlanılarak kazanılmıştır.
- Konusu bireysel ve toplumsal problemlerin sonucu olan sorunlardır.
- Bireysel ve toplumsal problemlerin çözümü, birey, grup ve toplum düzeyinde değişimler yaratmakla ilgilidir.
- Birey, grup ve toplum düzeyindeki değişimleri geliştirecek çeşitli teknikler: psikolojik, sosyal psikolojik, sosyolojik yan disiplinleriyle desteklenerek geliştirilir.
- Tanımı gereğince yapışdır.

Sosyal çalışmaya diğer disiplinlerde ayrılan üç temel nokta vardır:

- Sosyal çalışmanın sorun çözümüye yönelik olması,
- Sosyal çalışmanın uygulamalı niteliğinde olması,
- Sosyal çalışmanın insan yönü olarak ele alınması.

Sosyal çalışma tanımını içerdiği boyutlar şunlardır:

1. İnsanın ve toplumun değişime ve gelişimindeki dinamikleri ve yapısını,

2. Değişime dinamikleri ve bilgi,
3. İnsanın toplumsal etkinlikleri geliştirme yaklaşımı, yöntemi ve uygulamaları
4. Bilim dâli olma niteliklerinde değerlendirilmesi

Sosyal hizmetin amaçları, V. Duman tarafından şöylece belirtilmektedir:

1. Sosyal hizmet sorunları, insanların sorun çözme, hayata atma ve gelişim kapasitelerini artırmak kapsamında "gerevini içinde birey" kavramını kullanır. Uygulama düzeyinde sosyal hizmetin temel hedefi bireydir.
2. İnsanlara kaynak, hizmet ve fırsat sağlayan sistemler ve insanları bağlanmalarında kapsayıcı sosyal hizmet sunma yönü çevresel içinde birey kavramını kullanır.
3. Sosyal hizmet sunma sistemlerinin etkili ve insanca olarak işlev görmesini sağlar.
4. Sosyal politikaların geliştirilmesini ve ilerletmesini sağlamak adına sistemlerin etkili ve insanca çalışmasını geliştirir.
5. Risk altındaki grupları güçlendirir ve sosyal ve ekonomik adaleti sağlar.

Meslek Olarak Sosyal Çalışmanın Temel Nitelikleri

Birey ve toplumla ilgili bir uğraşın disiplin ve meslek olarak kabul görmesi için çeşitli ölçütlere başvurulabilir. Bunların başında bir mesleğin temel nitelikleri olarak sıralayabileceğimiz şu kavramlar gelir:

- Toplum
- Hedef kitle
- Belirli standartlara eğitim almış meslek elemanı
- Üstünlük hizmet
- Toplumsal yarar
- Mesleki özerklik

Sosyal hizmetin meslekleşmesindeki en önemli güçlük, kökenindeki sosyal yardımlaşma ve toplumsal dayanışma olmasıdır. Bu da mesleğin bilimsel bir araştırma kazanımına güçlenmiştir.

M. Arslan'a göre mesleklerin:

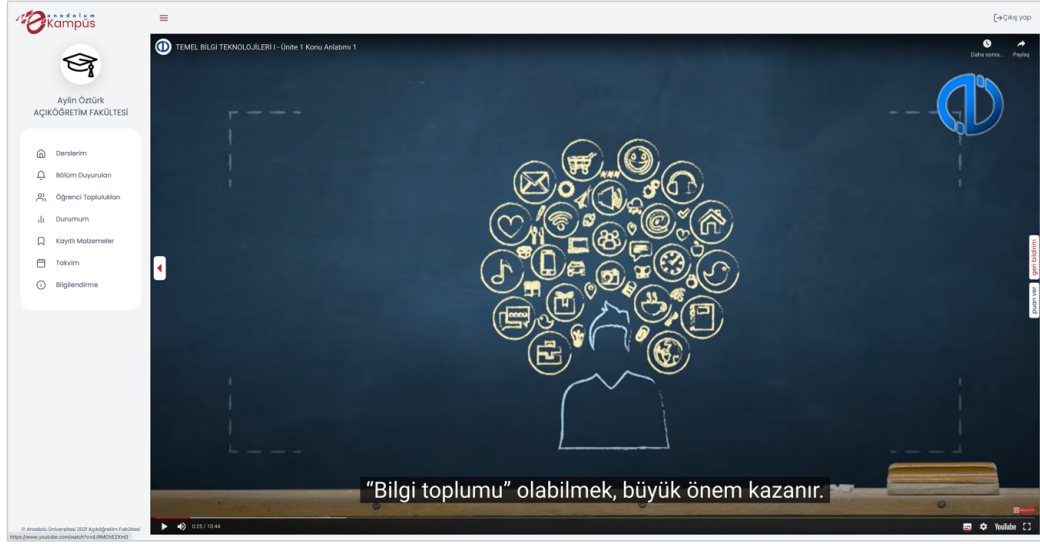
- Entellektüel bir boyutu vardır.
- Belirli bir akademik eğitime erişimi gerektirirler.

Meslekler, mensuplarından özerki, yani fedakarca davranışlar beklerler. Yani bir mesleğin mensuplarını ilk amaç, kendilerine ihtiyaç duyulan hizmet emelleridir. Bir meslekte, bütün meslek mensuplarının yeti alacağı eğitime bir meslek eğitimi de denir. Bu meslek eğitimi, örnek ve kendi kendini yönlendiren kolektif bir yapıda olmalı, mensupların kontrol edilebilir, onlara etibarlı yapmak, dinde standartlar geliştirme gibi sorunlarla karşılaşmalıdır. Bu öğretiler mensuplarına ayrıcalıklar da verebilir.

ANADOLU ÜNİVERSİTESİ

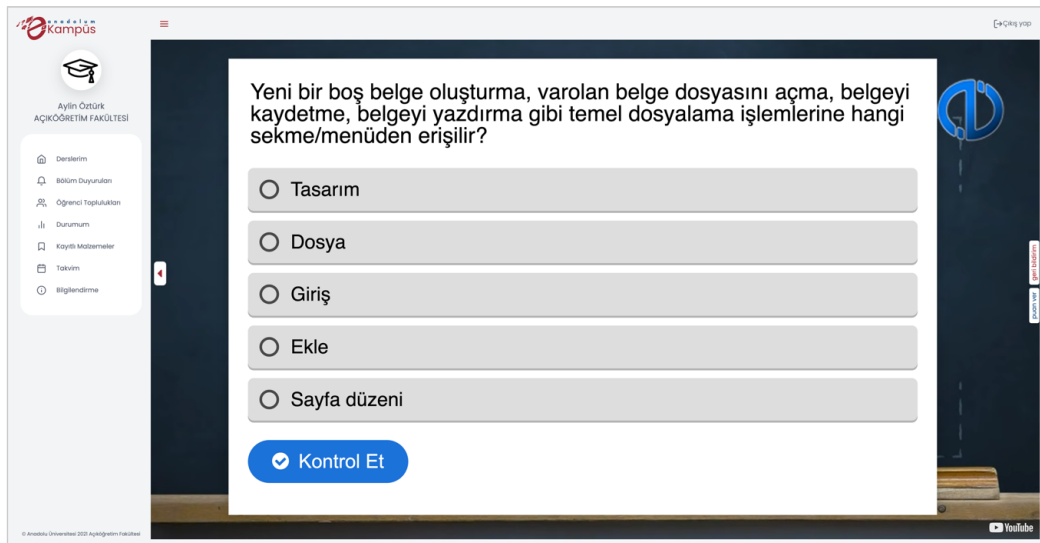
Görsel 1.10. Ünite örneği

Konu Tabanlı Video: Konu anlatım videoları alan uzmanları tarafından hazırlanan, üniteyi özetleyen anlatımlardan oluşan ve süresi 8-10 dakika arasında değişen videolardır (Görsel 1.11).



Görsel 1.11. *Konu tabanlı video örneği*

Soru Tabanlı Video: Bu alanda etkileşimli videolar yer almaktadır. Etkileşimli videolar; konu anlatım videolarına farklı formatlarda sorular, uyarılar ve hatırlatıcılar gibi etkileşim unsurları eklenerek hazırlanmış videolardır (Görsel 1.12).



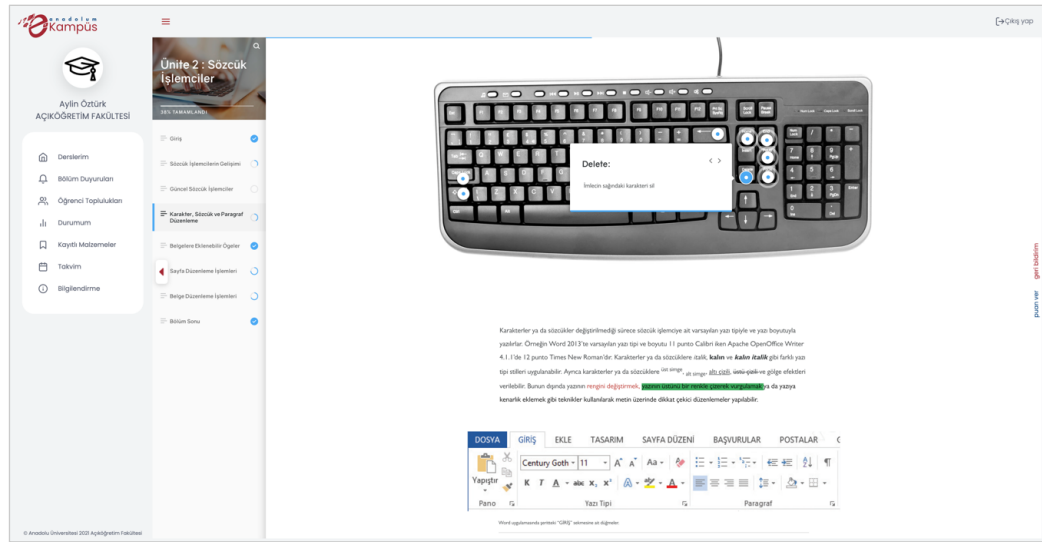
Görsel 1.12. *Soru tabanlı video örneği*

Animasyon Tabanlı Video: Bu videolar, mikroanimasyonlardan oluşmaktadır. Mikroanimasyon ilgili ünitenin önemli bölümlerinin ele alındığı 2-3 dakikalık animasyon videolardır (Görsel 1.13).



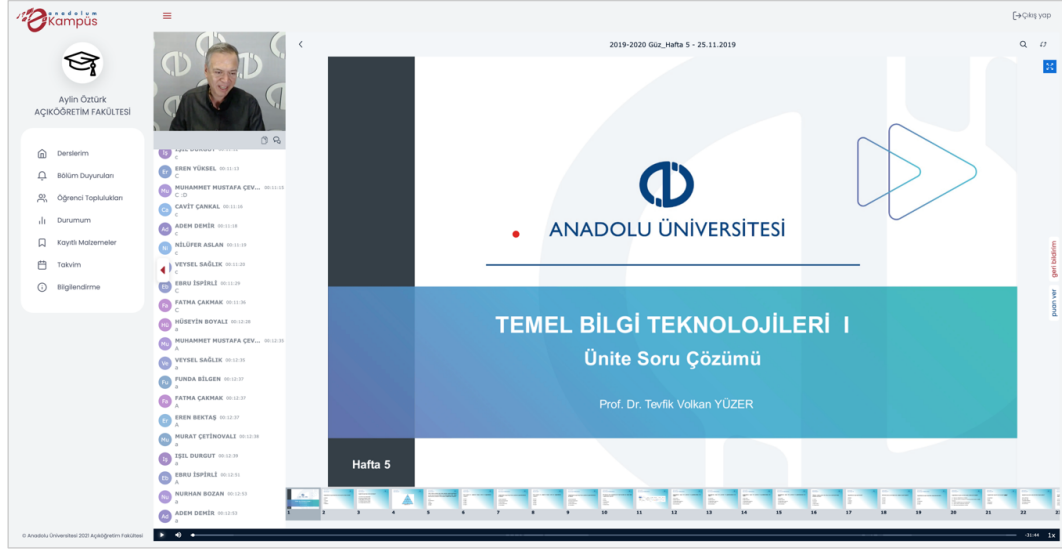
Görsel 1.13. Animasyon tabanlı video örneği

Etkileşimli İçerik: Bu içeriklerde, üniteler öğrenenlere etkileşimli ve aktif katılımlı bir biçimde sunulmaktadır. Bu malzemede hareketli dönen öğrenme kartları, açılır menüler, görseller, videolar ve etkileşim ve geri bildirim içeren sorular yer almaktadır (Görsel 1.14).



Görsel 1.14. Etkileşimli içerik örneği

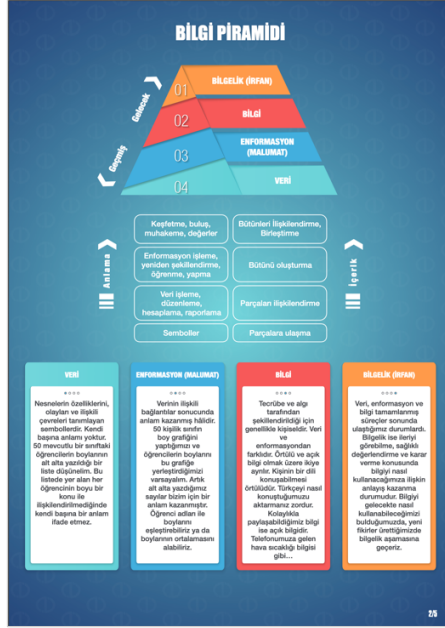
Canlı Ders Kayıtları: Bu bölümde haftalık olarak gerçekleştirilen canlı derslerin kayıtları yer almaktadır. Canlı derslere katılamayan ya da tekrar izlemek isteyen öğrenenler bu kayıtlardan canlı dersleri takip edebilmektedirler (Görsel 1.15).



Görsel 1.15. Canlı ders örneği

İnfoğrafik: Ünitelerin hatırlatıcılar aracılığıyla görselleştirildiği öğrenme malzemesidir (Görsel 1.16).

Çıkmış Sınav Soruları: Dersle ilgili önceki yıllarda yapılmış olan ara sınav, dönem sonu sınavı, tek ders sınavı ve yaz okulu sınavlarına ait sorular ve yanıtlarından oluşmaktadır (Görsel 1.16).



İnfoğrafik

Açıköğretim Sistemi ile ilgili merak ettiğiniz her şeyi AÖSDESTEK Sistemimizde, AÖSDESTEK Sistemimize sorabilirsiniz. anadokul.edu.tr adresinden ulaşabilirsiniz.

TEMEL BİLGİ TEKNOLOJİLERİ

2021 YAZ OKULU - A

1. Aşağıdakilerden hangisi giriş birimlerinden biridir?

A) İşaretli
B) Ekran
C) Yazıcı
D) Klavye
E) Projeksiyon cihazı

2. Markette barkod ile ürünün okunmasını sağlayan teknoloji aşağıdakilerden hangisidir?

A) Alıcama
B) Analiz
C) İşleme
D) Ölçümleme
E) Toplama

3. Etiler'de işlenilen patates ve diğer ürünlerin kalitesini kontrol etmek için kullanılan teknoloji aşağıdakilerden hangisidir?

A) Home
B) End
C) Silt
D) CapLock
E) Delete

4. Aşağıdakilerden hangisi işletim sistemi değildir?

A) Libre Office Writer
B) Windows 3.1
C) Google Docs
D) Open Office Writer
E) AppleWorks

5. Aşağıdakilerden hangisi dosya yöneticisi değildir?

A) İnt
B) İloc
C) İad
D) İlx
E) İpp

6. - Sunumlarında anlatımlarını en önemli noktalarını gösteren kısa bir özet yapar. - Çizimlere sademce için teşekkür edilip soru-cevap bölümü gerçekleştirir.

Yukarıda açıklanan sunum yazılımından hangisi değildir?

A) Görselleştirme
B) Aktarma
C) Kazanma
D) Hazırlama
E) Uyarılma

7. İşletimlerde ya da organizasyonlarda karar verme sürecini destekleyen bilgisayar destekli bilgi sistemlerine ne ad verilir?

A) Karar Destek Sistemi
B) Lisanslama Sistemi
C) Raporlama Sistemi
D) Öğrenme Sistemi
E) Yapılandırma Sistemi

8. Aşağıdakilerden hangisi masaüstü hesap tablosu yazılımlarından biri değildir?

A) Microsoft Excel
B) OpenOffice Calc
C) Sketchark
D) Lotus 1-2-3
E) Numbers

9. I. Veriler, Google sunucularında kriptografik anahtar kullanılarak gizlenir. II. Güvenlik gerektiren işlemlere izin verir. III. Yalnızca değişikliklerin yapılmasını için oturum açılıp kapatılması gerekir.

Yukarıda Google Chrome web tarayıcısı ile ilgili verilerden hangisi yanlıştır?

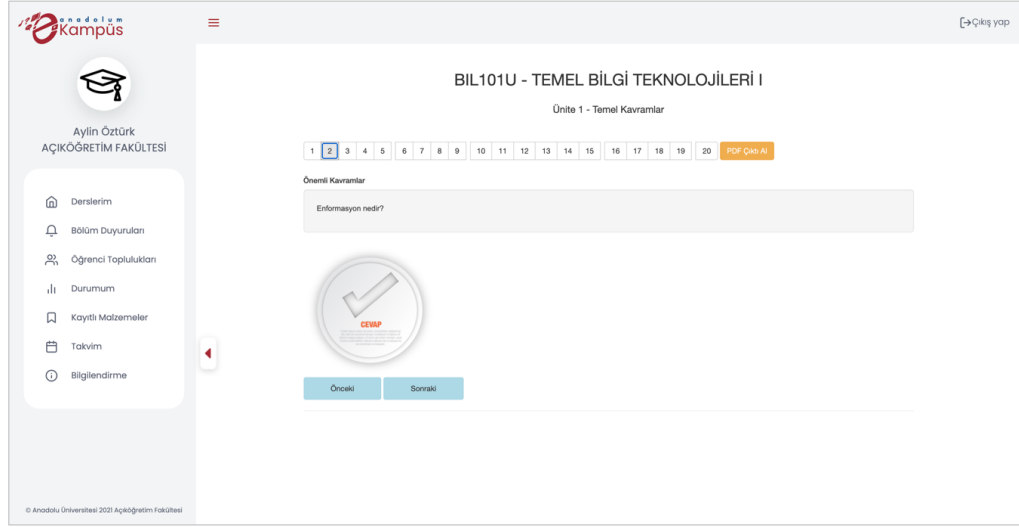
A) Yazıcı II
B) Yazıcı III
C) I ve II
D) I ve III
E) II ve III

Anadokul Üniversitesi tarafından hazırlanmıştır. Herhangi bir hakta saklıdır. Herhangi bir amaçla kullanılmaması veya başka amaçlarla kullanılması yasaktır. Bu yasağa uymayanlar gerekli cezai sorumluluğu ve hukuki sorumluluğu üstlenmek zorundadır. Anadokul Üniversitesi'ne karşı sorumlu değildir. Herhangi bir amaçla kullanılmaması veya başka amaçlarla kullanılması yasaktır.

Çıkmış Sınav Soruları

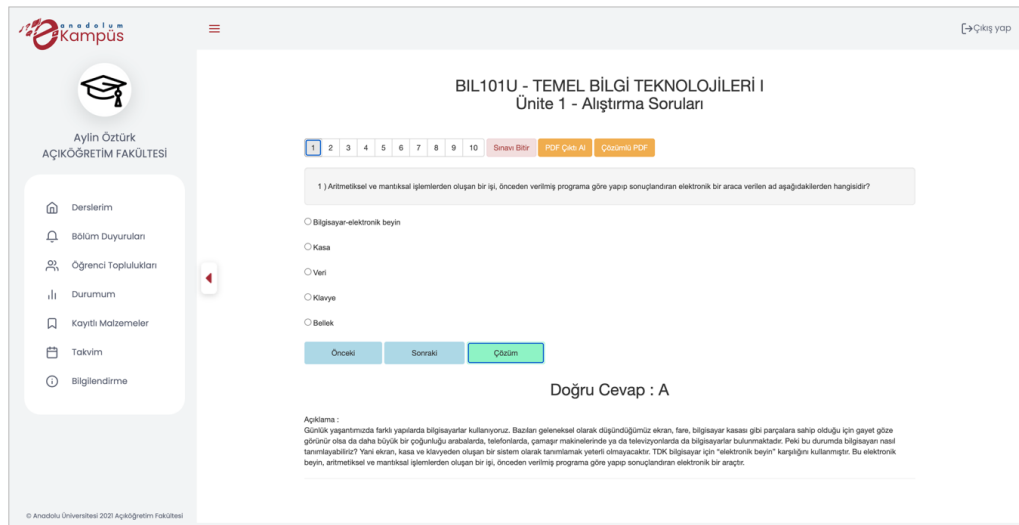
Görsel 1.16. İnfoğrafik ve çıkmış sınav soruları örnekleri

Sorularla Öğrenelim (Çevrimiçi): Ünitelerle ilgili 20 açık uçlu soru ve yanıtından oluşmaktadır (Görsel 1.17). Öğrenenler istedikleri sayıda Sorularla Öğrenelim malzemesi üretilip bunları PDF olarak çıktı alabilmektedirler.



Görsel 1.17. Sorularla öğrenelim örneği

Alıştırmalar (Çevrimiçi): Alıştırmalar, ünite bazlı olarak 10 çoktan seçmeli soru ve yanıtından oluşan çevrimiçi öğrenme malzemeleridir (Görsel 1.18). Deneme sınavlarına benzer olarak öğrenen, sınavı bitirdiğinde sınav sonucunu görebilir, PDF ya da çözümlü PDF olarak çıktı alabilir ve yeni sınav oluşturabilir.

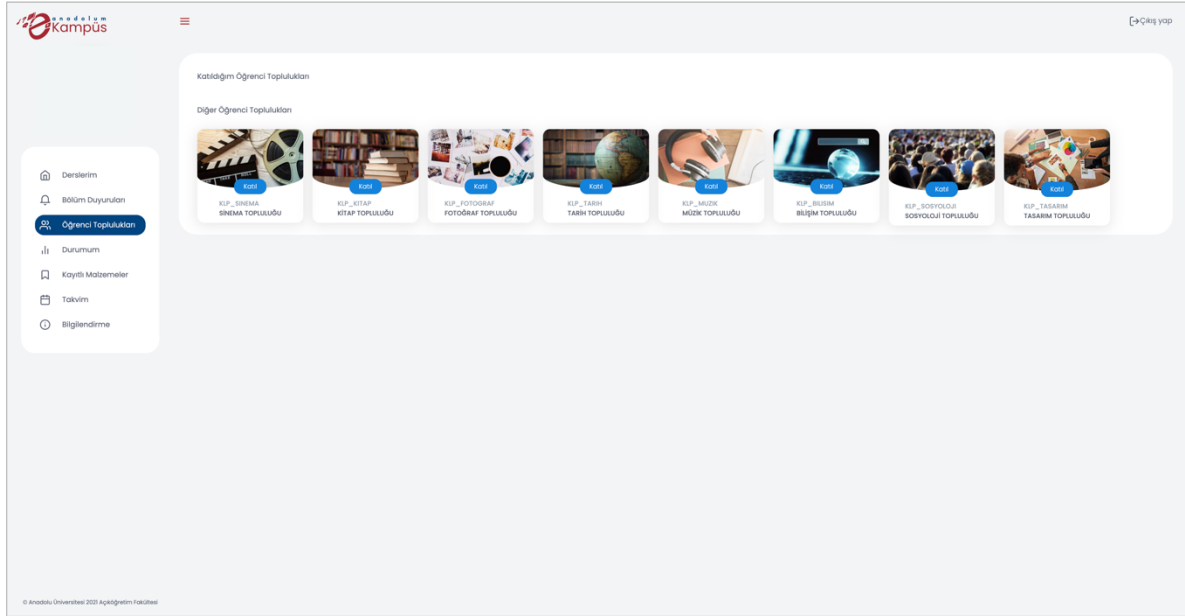


Görsel 1.18. Alıştırma örneği

Anadolium eKampüs üzerinden öğrenenlerin ihtiyaçları ve öğrenme özellikleri göz önüne alınarak farklı özelliklerdeki öğrenme malzemeleri sunulmaktadır. Bunun temel amacı, öğrenme sürecine destek olmak ve bu süreci iyileştirmektir. Öğrenme malzemelerinin geliştirilmesi ve iyileştirilmesinde yinelemeli bir süreç takip edilmektedir. Bunun için alan uzmanlarının ve öğrenenlerin görüşleri değerlendirilmektedir. Bunun yanı sıra, öğrenenler de Anadolu eKampüs üzerinden derslerindeki öğrenme malzemelerine puan ve geri bildirim vererek öğrenme malzemelerini değerlendirebilmektedirler.

Bölüm Duyuruları: Bu bölümde, öğrenenlerin bölümleri ile ilgili duyurular yer almaktadır.

Öğrenci Toplulukları: Öğrenenlerin ilgi alanlarına göre katıldıkları çevrimiçi topluluklardır. Bu kapsamda planlanan etkinlikler ve toplantılar, sanal ortamlar üzerinden gerçekleştirilmektedir. Öğrenci toplulukları, AÖS'teki öğrenenlerin sosyalleşmesi, birbirleriyle ve uzmanlar ile etkileşim kurabilmeleri amacıyla geliştirilmiştir. 2021-2022 öğretim yılında sinema, kitap, fotoğraf, tarih, müzik, bilişim ve sosyoloji toplulukları öğrenenlerin katılımına sunulmuştur (Görsel 1.19). Öğrenenler, “Katıl” butonuna tıklayarak topluluklara dahil olabilmektedirler.



Görsel 1.19. Öğrenci toplulukları ekranı

Durumum: Bu bölümde, öğrenenlerin ilgili dönem ve geçmiş dönemlere ait notları yer almaktadır.

Kayıtlı Malzemeler: Bu bölümde, öğrenenlerin favorilerine ekledikleri malzemeler yer almaktadır. Öğrenenler, daha sonra tekrar kullanmak istedikleri öğrenme malzemelerini işaretleyerek bu bölümden hızlıca erişebilmektedirler (Görsel 1.20).

The screenshot shows the 'Kayıtlı Malzemeler' (Registered Materials) page in the Anadolı University LMS. The page is organized into four main sections, each representing a different course or subject area. Each section contains a table of materials with columns for the material name, a status icon, and a 'Gör' (View) button.

SOSTİTÜ-DAVRANIŞ BİLMELERİ I	SOSTİTÜ-DAVRANIŞ BİLMELERİ I	SOSTİTÜ-DAVRANIŞ BİLMELERİ I	SOSTİTÜ-DAVRANIŞ BİLMELERİ I
Ünite Özet (pdf) - 1	3	Ünite Özet (pdf) - 2	1
Ünite Özet (pdf) - 3	2	Ünite Özet (pdf) - 4	1
Ünite Özet (pdf) - 5	1	Ünite Özet (pdf) - 6	1
Ünite Özet (pdf) - 7	1	Ünite Özet (pdf) - 8	1

SAĞLIKLI-SOSYAL HİZMETE GİRİŞ	SAĞLIKLI-SOSYAL HİZMETE GİRİŞ	SAĞLIKLI-SOSYAL HİZMETE GİRİŞ	SAĞLIKLI-SOSYAL HİZMETE GİRİŞ
Ünite Özet (pdf) - 1	2	Ünite Özet (pdf) - 2	1
Ünite Özet (pdf) - 3	1	Ünite Özet (pdf) - 4	1
Ünite Özet (pdf) - 5	1	Ünite Özet (pdf) - 6	1
Ünite Özet (pdf) - 7	1	Ünite Özet (pdf) - 8	1

ÇEKİTÜ-SOSYAL POLİTİKA	ÇEKİTÜ-SOSYAL POLİTİKA	ÇEKİTÜ-SOSYAL POLİTİKA	ÇEKİTÜ-SOSYAL POLİTİKA
Ünite Özet (pdf) - 1	1	Ünite Özet (pdf) - 2	1
Ünite Özet (pdf) - 3	1	Ünite Özet (pdf) - 4	1
Ünite Özet (pdf) - 5	1	Ünite Özet (pdf) - 7	2
Ünite Özet (pdf) - 8	1		

HUKİTÜ-TEMEL İNSAN HAKLARI BİLGİSİ I	HUKİTÜ-TEMEL İNSAN HAKLARI BİLGİSİ I	HUKİTÜ-TEMEL İNSAN HAKLARI BİLGİSİ I	HUKİTÜ-TEMEL İNSAN HAKLARI BİLGİSİ I
Ünite Özet (pdf) - 1	1	Ünite Özet (pdf) - 2	1
Ünite Özet (pdf) - 3	1	Ünite Özet (pdf) - 4	1
Ünite Özet (pdf) - 5	1	Ünite Özet (pdf) - 6	1

Görsel 1.20. Kayıtlı malzemeler ekranı

Takvim: Öğrenenler bu bölümden canlı ders takvimine ve akademik takvime erişebilmektedirler (Görsel 1.21).

© Anadolu Üniversitesi 2023 Açıköğretim Fakültesi
Eğilim Kampüsü anadolui.edu.tr/EdKampus

Görsel 1.21. Takvim ekranı

Bilgilendirme: Öğrenenler bu bölümden öğrenme malzemeleri ile ilgili geri bildirimlerine ve sınav sorumluluk ünitelerine erişebilmektedirler (Görsel 1.22).

Derslerim	Ara Sınav	Dönem Sonu	Yaz Okulu
0001_ORYANTASYON- ORYANTASYON VE BEYBESLİK	1	1	1
SOSYAL-DAVRANŞ BİLEMLERİ I	12.3.4	12.3.4.5.6.7.8	12.3.4.5.6.7.8
SHZDÜ-SOSYAL HİZMETE GİRİŞ	12.3.4	12.3.4.5.6.7.8	12.3.4.5.6.7.8
CEKÜDÜ-SOSYAL POLİTİKA	12.3.4	12.3.4.5.6.7.8	12.3.4.5.6.7.8
HUKUKU-TEMEL İNSAN HAKLARI BİLGİSİ I	12.3.4	12.3.4.5.6.7.8	12.3.4.5.6.7.8
İNGİLİZCE I	12.3.4.5.6	12.3.4.5.6.7.8.9.10.11.12	12.3.4.5.6.7.8.9.10.11.12
SHZDÜ-İNSAN DAVRANŞI VE SOSYAL ÇEVRE I	12.3.4	12.3.4.5.6.7.8	12.3.4.5.6.7.8


© Anadolu Üniversitesi 2023 Açıköğretim Fakültesi
Eğilim Kampüsü anadolui.edu.tr/EdKampus

Görsel 1.22. Bilgilendirme ekranı

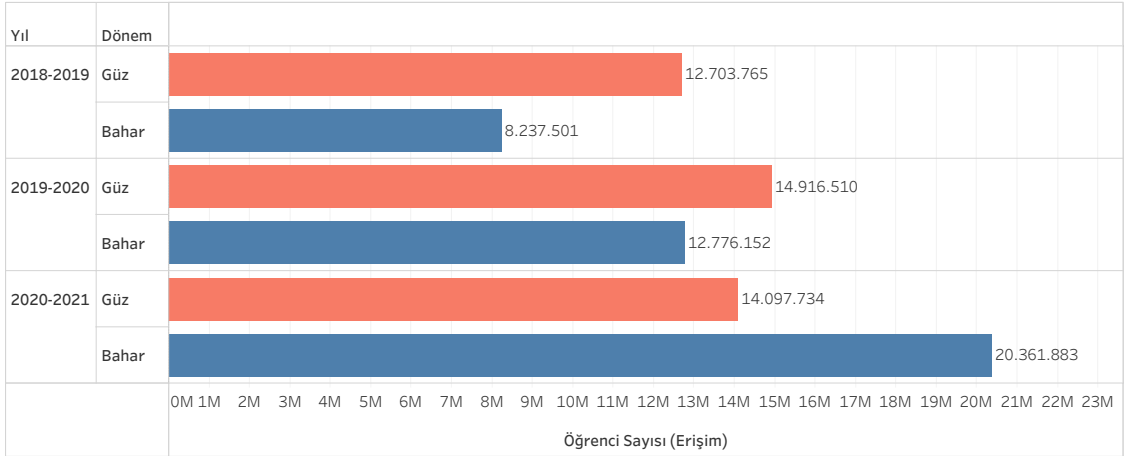
1.9.2.3. Anadolu eKampüs kullanım oranları

Anadolu eKampüs, AÖS öğrenenleri tarafından farklı özellikteki öğrenme malzemelerine erişebilmek amacıyla yaygın olarak kullanılmaktadır. Şekil 1.4'te Anadolu eKampüs'e giriş yapan tekil öğrenen sayısı ve ilgili dönemler boyunca yaptıkları toplam giriş sayıları gösterilmektedir.

Anadolu eKampüs Giriş Sayısı (Tekil)



Anadolu eKampüs Giriş Sayısı (Toplam)




Şekil 1.4. Yıl ve dönem bazında Anadolu eKampüs tekil ve toplam giriş sayıları

Şekil 1.4 incelendiğinde Anadolu eKampüs'ün dönemlik ortalama 747.972 öğrenen tarafından kullanıldığı söylenebilir. Kayıtlı öğrenen sayıları açısından değerlendirildiğinde öğrenenlerin %70'ten fazlasının Anadolu eKampüse giriş yaptığı ve bu oranın yıllar

bazında yükseldiği görülmektedir. Toplam giriş sayıları açısından incelendiğinde ise bir öğrenenin dönemlik olarak ortalama 19 kez sisteme giriş yaptığı belirtilebilir. Tüm dönemlerde tekil erişim ile toplam erişim sayıları birbirine paralellik göstermekle birlikte 2020-2021 öğretim yılı Bahar döneminde bunun tersi bir durum söz konusudur. Bu dönemde tekil giriş sayısı azalmasına rağmen toplam giriş sayısı artış göstermiş ve ortalama sistem girişi 24'e yükselmiştir.

Şekil 1.5'te sisteme giriş yapan öğrenenler (tekil) yaş grupları bağlamında incelenmiştir.




Şekil 1.5. Yaş gruplarına göre yıl ve dönem bazlı Anadolu eKampus giriş sayıları

Şekil 1.5 incelendiğinde sisteme en çok giriş yapan öğrenenlerin 26-33 yaş aralığında olduğu görülmektedir. Ancak bu, kayıtlı öğrenenlerin yaş grupları göz önüne alındığında beklenen bir durumdur. Şekil 1.5, kayıtlı öğrenenlerin yaş grupları açısından değerlendirildiğinde 18-25 yaş aralığındaki öğrenenlerin %73'ünün, 26-33 yaş aralığındaki öğrenenlerin %66'sının, 34-42 yaş aralığındaki öğrenenlerin %77'sinin, 42 yaş ve üstündeki

öğrenenlerin ise %81'inin sisteme giriş yaptıkları belirlenmiştir. Bu verilere göre Anadolu eKampüs'e en fazla giriş yapan öğrenenlerin 42 yaş ve üstü olduğu söylenebilir.

Şekil 1.6'da sisteme giriş sayıları cinsiyetler bağlamında sunulmuştur.

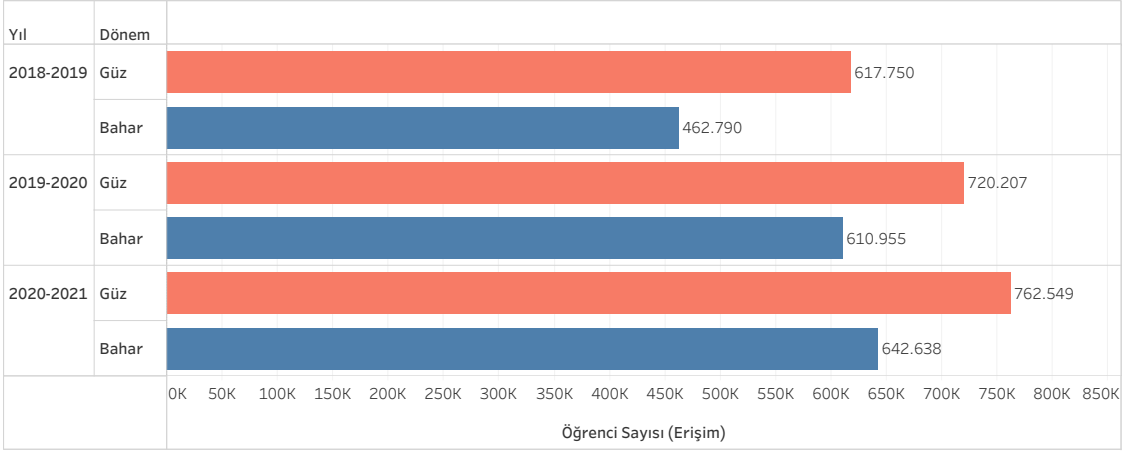


Şekil 1.6. Cinsiyetlere göre yıl ve dönem bazlı Anadolu eKampüs giriş sayıları

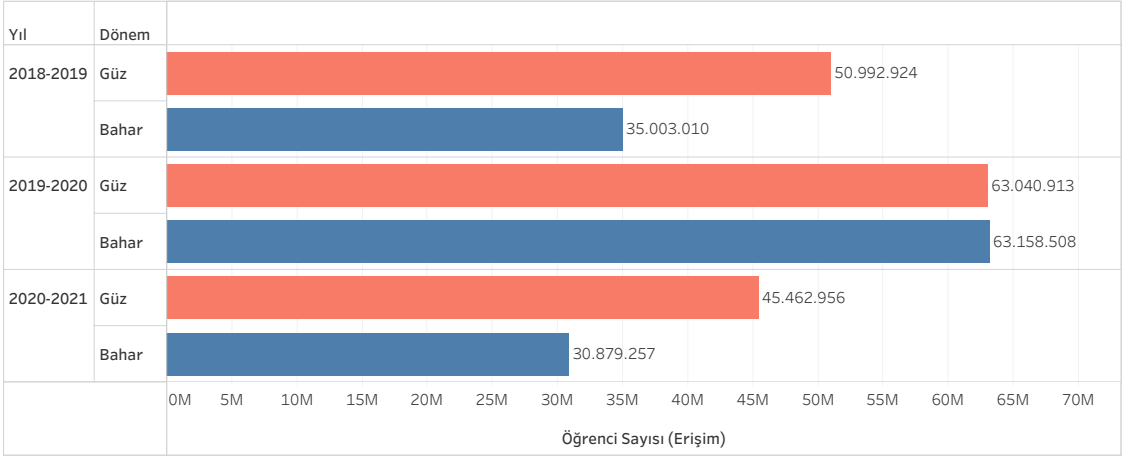
eKampüs'e tekil giriş sayıları cinsiyetler bağlamında değerlendirildiğinde kadınların sisteme daha fazla giriş yaptığı görülmektedir. Bu durum kayıtlı öğrenen sayıları göz önüne alınarak incelendiğinde kadın öğrenenlerin %80'inin, erkek öğrenenlerin ise %66'sının sisteme giriş yaptığı belirlenmiştir. Bu bağlamda kadın öğrenenlerin erkek öğrenenlerden daha fazla sisteme giriş yaptıkları söylenebilir.

Şekil 1.7'de öğrenenlerin öğrenme malzemesi erişim sayıları tekil ve toplam olarak sunulmaktadır.

Öğrenme Malzemelerine Erişim Sayısı (Tekil)



Öğrenme Malzemelerine Erişim Sayısı (Toplam)



Şekil 1.7. Yıl bazında öğrenme malzemelerine tekil ve toplam erişim sayıları

Şekil 1.7 incelendiğinde Anadolu eKampus'teki öğrenme malzemelerine dönemlik ortalama 636.148 öğrenen tarafından erişildiği söylenebilir. Kayıtlı öğrenen sayıları açısından değerlendirildiğinde, öğrenenlerin %60'tan fazlasının öğrenme malzemelerine eriştiği belirlenmiştir. Toplam öğrenme malzemesi erişim sayıları açısından incelendiğinde ise bir öğrenenin dönemlik olarak ortalama 76 defa öğrenme malzemelerine eriştiği belirtilebilir. Tüm dönemlerde tekil erişim ile toplam erişim sayıları birbirine paralellik göstermekle birlikte 2019-2020 öğretim yılı Bahar döneminde öğrenme malzemeleri erişiminde artış olduğu ve bir öğrenenin dönemlik olarak ortalama 103 defa öğrenme malzemelerine eriştiği belirlenmiştir.

2. ALANYAZIN

Bu bölüm; araştırma soruları bağlamında çevrimiçi öğrenme ortamlarında öğrenen davranışları ve profilleri, öğrenen performansı tahmini ve performans değerlendirme panelinin uygulamaları ile ilgili yapılan çalışmaları içermektedir.

2.1. Çevrimiçi Öğrenme Ortamlarında Öğrenenlerin Davranış Örüntüleri

Çevrimiçi öğrenme ortamlarında öğrenenlerin her hareketi kayıt altına alınmaktadır. Bu ortamlar aracılığıyla öğrenenlerin sisteme giriş ve çıkış zamanları, sistem erişim sıklıkları, öğrenme malzemeleri erişim durumları ve süreleri, oluşturdukları deneme sınavları ve puanları gibi etkinlik verileri depolanabilmektedir. Çevrimiçi öğrenme etkinliklerinin daha iyi anlaşılabilmesi için öğrenenlerin davranış örüntüleri belirlenebilir. Bu alanda yapılan çalışmalar incelendiğinde çalışmaların çoğunlukla tek bir ders bağlamında ve az sayıda öğrenen ile gerçekleştirildiği görülmektedir. Buna ek olarak, çalışmaların çoğunda öğrenenlerin sistem kullanım davranışları analiz edilmiştir. Bu çalışmada ise bunlardan farklı olarak öğrenme sürecinin daha detaylı gözlenebilmesi için öğrenme malzemeleri kullanım örüntüleri incelenmiştir.

Gezinme davranışı, öğrenenlerin dersteki hareketlerini, hangi öğrenme nesnelere eriştiklerini ve hangi sırayla öğrenme malzemelerini kullandıklarını ifade etmektedir (Graf vd., 2010). Öğrenenlerin gezinme davranışları analiz edilerek dijital ayak izleri oluşturulabilir. Böylece öğrenenlerin öğrenme süreçlerine yönelik daha detaylı bilgi elde edilebilir. Çevrimiçi öğrenme ortamlarında öğrenenlerin davranış örüntülerinin belirlenmesi için birliktelik kuralları, sıralı örüntü madenciliği ve ilişki madenciliği gibi makine öğrenmesi yöntemleri kullanılabilir (Romero ve Ventura, 2020).

Çevrimiçi ve harmanlanmış öğrenme ortamlarında öğrenenlerin gezinme davranışlarının incelendiği çalışmalar, çoğunlukla öğrenme stilleri bağlamında ele alınmıştır. Graf vd. (2010) yaptıkları çalışmada çevrimiçi bir dersteki öğrenenlerin gezinme davranışlarını ve öğrenme stillerini incelemişlerdir. Öğrenenlerin öğrenme yönetim sistemi üzerindeki davranışları farklı öğrenme stilleri bağlamında ele alınmıştır. Çalışmada farklı öğrenme stiline sahip olan öğrenenlerin derste farklı gezinme davranışları gösterdikleri ve farklı öğrenme stratejilerine sahip oldukları belirlenmiştir. Benzer olarak, Nakić vd. (2011)

de çalışmalarında web tabanlı öğrenmede öğrenme stilleri ve gezinme örüntülerini incelemişlerdir. Buna ek olarak çalışmada, öğrenme stilleri ve performans arasındaki ilişki de incelenmiştir. Çalışmada gezinme örüntüleri ile öğrenme çıktıları arasında bir ilişki olduğu belirlenmiştir.

Poon vd. (2017), çalışmalarında öğrenenlerin öğrenme yönetim sistemindeki gezinme örüntülerini ortaya çıkarmak için veri madenciliği ve görselleştirme tekniklerini kullanmışlardır. Çalışmada lisans düzeyinde harmanlanmış bir istatistik dersindeki öğrenenlere ait veriler, sıralı örüntü madenciliği kullanılarak analiz edilmiştir. Çalışmada SPM algoritmasıyla 0,5 destek seviyesinde 83 sıralı örüntü elde edilmiştir. Ziebarth vd. (2015) harmanlanmış bir derste öğrenenlerin sınava hazırlanma sürecindeki kaynak kullanım örüntülerini incelemişlerdir. Çalışmada birliktelik kuralları ve sıralı örüntü madenciliği kullanılmıştır. Elde edilen sıralı örüntüler öğrenen grupları bazında değerlendirildiğinde; en düşük ortalama nota sahip Grup 1'deki öğrenenlerin sadece video, benzer olarak Grup 3 ve Grup 4'teki öğrenenlerin ise sadece wiki makalelerinin kural çıktılarında yer aldığı görülmüştür. Daha yüksek ortalama nota sahip olan Grup 6 için, kaynak kullanımında sık görülen örüntülerin iki bilimsel makale, bir ders sunumu, bir video ve 2 wiki makalesi olmak üzere dört farklı kaynaktan ve 6 nesneden oluştuğu belirlenmiştir. Grupların not ortalamalarının, kaynak kullanım sayısı ile ilişkili olabileceği belirtilmiştir. Aynı seviyedeki öğrenenlerin benzer kaynaklara aynı şekilde eriştikleri ifade edilmiştir. Çalışmanın sonuçları, sınava hazırlık aşamasında, öğrenenlerin ortak örüntüler gösterdiklerini ortaya koymuştur. Ozturk ve Kumtepe (2019) çalışmalarında, çevrimiçi bir ders kapsamında öğrenme yönetim sistemini kullanan 20.996 öğrenenin öğrenme malzemesi kullanım davranışlarını analiz etmişlerdir. Çalışmanın sonucunda, öğrenenler tarafından en çok tercih edilen öğrenme malzemeleri ve malzeme kullanım alışkanlıkları ortaya çıkarılmıştır. Buna ek olarak, birliktelik kuralları algoritmaları kullanılarak öğrenenlerin öğrenme malzemelerine erişimlerine yönelik 8 farklı birliktelik kuralı bulunmuştur. Çalışmanın sonuçları birliktelik kurallarının çıktılarında çoğunlukla ünite özeti kullanımının yer aldığını göstermiştir.

Hung ve Zhang (2008), çevrimiçi bir derste 98 öğrenenin öğrenme davranışlarını inceledikleri çalışmalarında en sık görülen öğrenme etkinlikleri ile gönderilen ve okunan toplam mesaj sayısı ve ders malzemelerine erişim sıklığı arasındaki ilişkiyi incelemişlerdir. Çalışmanın sonucunda öğrenenlerin mesaj göndermek yerine okumayı tercih ettiği,

öğrenenlerin oturum açma durumlarının yaklaşık %26'sının haftalık görevlerin başladığı Salı günü olduğu görülmüştür. Sisteme en az sayıdaki girişin ise Cuma ve Cumartesi günleri olduğu belirtilmiştir. Öğrenenlerin ilk hafta ve proje görevlerini tamamladıkları hafta en fazla oturum açtıkları belirlenmiştir. Oturum açma sıklığının %41'i bu iki haftada gerçekleşmiştir. Öğrenenlerin öğrenme ortamındaki davranış örüntülerinin belirlenmesi için sıralı birliktelik kuralları kullanılmıştır. En yüksek destek değerine sahip kural; öğrenme malzemelerine erişim, ders duyurularını ve kendi alanındaki kayıtları kontrol etmek olarak belirlenmiştir. Cruz-Benito vd. (2015) tarafından sanal bir öğrenme ortamında kullanım davranışlarının ve katılımın keşfedilmesinin amaçlandığı çalışmada, daha fazla oturum açan öğrenenlerin daha fazla kaynak ve araç kullandıkları belirlenmiştir. Aynı zamanda sanal öğrenme ortamında daha fazla zaman geçiren öğrenenlerin öğrenme nesnelere ile diğer öğrenenlerden daha fazla etkileşime girme eğiliminde oldukları ifade edilmiştir. Sanal öğrenme ortamında en çok zaman geçiren öğrenenlerin %50'den fazlasının diğer öğrenenlere kıyasla 3 boyutlu öğeler içeren öğrenme nesnelereyle daha fazla etkileşime girdiği belirlenmiştir. Bu çalışmalardan farklı olarak Tlili vd. (2021), çevrimiçi bir dersteki öğrenme davranışlarını kültürel boyutta değerlendirmişlerdir. Çalışma, 116 öğrenene ait veriler üzerinde LSA (lag sequential analysis) algoritması kullanılarak gerçekleştirilmiştir. Çalışmanın bulguları, kültürün öğrenenlerin tartışmalara nasıl katıldıklarını ve çevrimiçi öğrenme performanslarını nasıl sürdürdüklerini etkileyebileceğini vurgulamaktadır. Bulgular ayrıca, çevrimiçi öğrenme deneyimlerinin Arap kültürlerinde sosyal baskılar yaşayan kadın öğrenenler için faydalı olabileceğini göstermektedir. Bu çalışma sonucunda ders modülü görüntüleme, ders modülü tamamlama, ödev forumu görüntüleme, ödev yükleme, tartışma forumu görüntüleme ve forumdaki mesajları görüntüleyen diğer öğrenenlerin listelenmesi davranışlarının en sık olarak görülen çevrimiçi davranışlar olduğu belirlenmiştir.

2.2. Çevrimiçi Öğrenme Ortamlarında Öğrenen Profilleri

Öğrenen profilleri, öğrenenlerin demografik özellikleri, çevrimiçi öğrenme ortamındaki davranışları ve sınav puanları gibi verilerinin analiz edilmesiyle öğrenenlerin benzer özelliklerine göre gruplanması olarak ifade edilebilir. Öğrenen profilleri, açık ve uzaktan öğrenme kurumlarında öğrenenlerin derinlemesine anlaşılmasına ve buradan elde

edilen bilgilerle bireye özgü hizmetlerin sunulmasına olanak sağlayabilir. Öğrenen profillerinin oluşturulması ile ilgili alanyazında yapılan çalışmalar incelendiğinde, çalışmaların çoğunlukla kişiselleştirme amacıyla zeki öğretim sistemleri ve uyarlanabilir öğrenme ortamlarında gerçekleştirildiği görülmektedir. Buna ek olarak, profil çalışmaları öğrenme kalitesinin yükseltilmesi, destek ve öneri sistemlerinin tasarlanması amacıyla da kullanılmaktadır. Öğrenen profillerinin belirlenmesinde öğrenenlerin demografik özellikleri, geçmiş akademik yaşantılarına ilişkin veriler, ÖYS kullanma ve gezinme verileri gibi farklı veri kaynaklarından elde edilen veriler kullanılmaktadır. Alanyazındaki profil çalışmalarında yaygın olarak kullanılan yöntemler ise, kümeleme ve sınıflandırma yöntemleridir.

Açık ve uzaktan öğrenme ortamlarında öğrenen profillerinin belirlenmesine yönelik alanyazındaki çalışmalar farklı öğrenme ortamlarında, farklı veri kaynakları ve algoritmalar kullanarak gerçekleştirilmiştir. Yukselturk ve Top (2013), çevrimiçi bir dersteki öğrenenlerin giriş özellikleri, öğrenme ortamı katılım davranışları ve ders çıktıları değişkenlerini kullanarak öğrenen profillerini belirlemişlerdir. Çalışma, çevrimiçi olarak sunulan bir sertifika programında eğitim alan 186 öğrenen ile gerçekleştirilmiştir. Öğrenenlere ait veriler üzerinde TwoStep algoritması kullanılarak kümeleme analizi gerçekleştirilmiş ve 3 küme elde edilmiştir. Yapılan analizlerin sonucunda, cinsiyet ve çalışma durumuna göre kümeler arasında anlamlı bir farklılık olduğu, öğrenenlerin çalışma durumu özelliklerinin ise sadece erkekler için istatistiksel olarak anlamlı olduğu belirlenmiştir. Kümeler, çalışan erkekler (Küme 1), çoğunlukla kadın (Küme 2) ve çalışmayan erkekler (Küme 3) olarak gruplanmıştır. Sürekli değişkenlerden ise çevrimiçi teknolojiler özyeterliliği, sohbet oturumlarına katılım, tartışma forumlarına katılım ve yaş açısından kümeler arasında istatistiksel olarak anlamlı farklılıklar bulunmuştur. Yazarlar, öğrenenlerin giriş özelliklerinin ve katılım davranışlarının öğrenen profillerinin belirlenmesinde ayırt edici değişkenler olduğunu belirtmişlerdir. Jovanovic vd. (2012) ise çalışmalarında, e-öğrenenleri bilişsel stillerine göre gruplamayı ve öğrenen performansını tahmin etmeyi amaçlamışlardır. Yazarlar, Moodle ÖYS'den elde edilen verileri kullanarak e-öğrenme kaynakları kullanımına yönelik öğrenen davranışlarını belirlemişler ve öğrenen başarısını tahmin etmişlerdir. Öğrenenlerin bilişsel stillerinin belirlenmesi için Moodle ÖYS üzerinden anket uygulanmıştır. Öğrenenler, bu anket sonucunda oluşturulan bilişsel stilleri ve ders notları kullanılarak gruplandırılmıştır. Gruplandırma için k-Means algoritması kullanılmıştır.

Kümeler, ders temelli olarak oluşturulmuş ve farklı derslerde farklı öğrenen gruplarının ortaya çıktığı belirtilmiştir. Diğer yandan Hogo (2010), e-öğrenenlerin davranışlarını değerlendirmek için bulanık kümeleme yaklaşımını kullanmıştır. Çalışmada iki farklı derse kayıtlı toplam 163 öğrenene ait veriler analiz edilmiştir. Çalışmada, karar vericilere geri bildirim sağlayabilecek e-öğrenen davranışlarına yönelik evrimsel yöntemler önerilmiştir. Yazar, öğrenen profillerini belirlemek için bulanık c-means ve çekirdek bulanık c-means gibi bulanık kümeleme yöntemlerini kullanmıştır. Kümeleme analizinde web sitesi kullanım verileri ve davranış verileri kullanılmıştır. İlk derste öğrenenlere ait veriler ile 7 küme, ikinci derste ise 5 küme elde edilmiştir. Öğrenen kümeleri düzenli, çalışan, ilgisiz, vasat ve devamsız olarak isimlendirilmiştir. Çalışmada farklı kümeleme analizi algoritmaları karşılaştırılmış ve bulanık kümelemenin kesin kümelemeye göre öğrenen davranışlarını daha çok yansıttığı belirtilmiştir. Elde edilen sonuçların analizi ve öğrenenlerin gerçek hayattaki davranışlarının karşılaştırılması sonucunda %78 oranında bir eşleşme olduğu ortaya konulmuştur. Bu çalışmalardan farklı olarak Dwivedi ve Bharadwaj (2015), e-öğrenme ortamlarında bireylerden ziyade öğrenen gruplarına kaynak önerilmesi problemini incelemişlerdir. Öğrenen profillerinin oluşturulması için öğrenenlerin öğrenme stilleri, bilgi düzeyleri ve kullandıkları malzemelere ilişkin değerlendirmeleri kullanılmıştır. Çalışma kapsamında geliştirilen tümleşik öğrenen profili kullanılarak öğrenen gruplarına kaynak önerileri sunmak için işbirliğine dayalı filtreleme çerçevesi sunulmuştur. Çalışmada geliştirilen öneri sistemi klasik öneri sistemleri ile karşılaştırılmış ve geliştirilen sistem, deneysel araştırmalar sonucunda daha başarılı bulunmuştur. Yazarlar, gruplara yönelik geliştirilen öneri sistemlerinde, farklı öğrenenlerin bireysel tercihlerinin bir araya getirilmesinin büyük bir zorluk olduğunu ve e-öğrenme alanında grup önerisi çalışmalarının az sayıda olduğunu belirtmişlerdir.

Öğrenen profillerinin belirlenmesi çalışmaları, uyarlanabilir e-öğrenme ortamlarında dinamik olarak güncellenen öğrenen profillerinin oluşturulması ve ortaya çıkan profillerin farklı öğrenme ortamlarında test edilmesi amacıyla da gerçekleştirilmektedir. Rezaei ve Montazer (2016), uyarlanabilir bir e-öğrenme sistemindeki hizmetleri öğrenenlere göre özelleştirmek amacıyla öğrenenlerin kişisel özelliklerine, davranışlarına ve öğrenme stillerine göre gruplar oluşturmuşlardır. Öğrenen gruplarının oluşturulması için 4 adımlı kümeleme çalışması yapmışlar ve farklı algoritmaları birlikte kullanmışlardır. Yazarlar,

otomatik olarak öğrenen gruplarını oluşturabilen yeni bir uyarlanabilir öğrenme sistemi sunmuşlardır. Yapılan değerlendirmeler sonucunda, akademik memnuniyet ve ilerleme açısından, sunulan sistemin e-öğrenme ortamlarında önemli gelişmeler ortaya çıkarabileceği belirtilmiştir. Öte yandan Premlatha vd. (2016), uyarlanabilir e-öğrenme ortamındaki öğrenenlerin değişen tercihlerine ve gereksinimlerine göre güncellenen dinamik bir öğrenen profillemesi sunmuşlardır. Öğrenen profili parametreleri, her bir öğrenenin öğrenme yolunu belirlemeyi kolaylaştıran, öğrenen davranışlarını ve tercihlerini dinamik olarak gözlemleyebilen renkli Petri ağları kullanılarak tanımlanmıştır. Öğrenen davranışlarında değişiklik olması durumunda profiller otomatik olarak güncellenmiştir. Çalışmada öğrenenler öğrenme türlerine göre çalışkan ve başarılı öğrenenler, düzenli çalışan ve zeki öğrenenler, yavaş öğrenenler ve az çalışan öğrenenler olmak üzere 4 sınıfta incelenmişlerdir. Bu çalışma, iki farklı uyarlanabilir e-öğrenme sisteminde 120 öğrenen ile test edilmiştir. Test sonucunda öğrenenler, dinamik öğrenen profilinin kullanıldığı uyarlanabilir e-öğrenme ortamını dersi tamamlamak için daha motive edici ve memnuniyet verici olarak belirtmişlerdir. Amershi ve Conati (2009), keşfedici öğrenme ortamlarında öğrenen modelleri oluşturmak için hem gözetimli hem de gözetimsiz öğrenmenin kullanıldığı bir kullanıcı modelleme çerçevesi sunmuşlardır. Çalışma, Bilgisayar Bilimleri ve Mühendislik öğrenenlerinden oluşan iki farklı grup üzerinde gerçekleştirilmiştir. Birinci grup 36, ikinci grup 24 öğrenenden oluşmuştur. Çalışmada, arayüz etkileşim ve göz izleme verileri kullanılmıştır. Çalışma, çevrimdışı ve çevrimiçi tanıma olarak iki aşamalı planlanmıştır. Çalışmanın ilk aşamasında, k-Means algoritması kullanılarak kümeleme analizi yapılmıştır. Çevrimiçi tanıma aşamasında ise ilk aşamada tanımlanan kümeler, sınıflandırıcı bir kullanıcı modelini eğitmek için kullanılmıştır. Bu aşamada yazarlar, geliştirdikleri çevrimiçi k-Means sınıflandırıcısını kullanmışlardır. Bu sınıflandırıcı ile sisteme yeni giren bir öğrenenin sınıfı, öğrenme ortamı ile etkileşimine bağlı olarak, kademeli olarak güncellenmiştir. Geliştirilen kullanıcı modeli çerçevesi iki öğrenme ortamında uygulanmış ve oluşturulan çerçevenin otomatik olarak öğrenenlerin anlamlı etkileşim davranışlarını tespit edebildiği belirtilmiştir. Bouchet vd. (2013), zeki bir öğretim sisteminde yer alan öğrenenleri etkileşimlerine göre gruplandırmışlar ve öğrenen profillerini oluşturmuşlardır. Yazarlar, öğrenenlerin zeki bir öğretim sistemindeki performanslarına ve etkileşimlerine göre öğrenen kümelerinin belirlenmesi problemini ve kümelerin oluşturulmasındaki ayırt edici değişkenlerin neler

olduğunu incelemiştir. Çalışma, Kuzey Amerika’da 2 devlet üniversitesinde MetaTutor adı verilen zeki öğretim sistemini kullanan 106 üniversite öğrencisi ile gerçekleştirilmiştir. Kümelerin belirlenmesinde öğrenenlerin ön teste verdikleri doğru cevap sayısı, çoklu ortam içeriklerini okumak için harcadıkları süre, gerçekleştirilen alt amaç oranı, yeni bir alt amaca başlama sayısı, alt hedefle ilişkili bir sınava ilk kez katıldıklarında verdikleri doğru cevapların ortalama puanı, alt hedef sınavlarına katılım sayısı, tek tek sayfalarda cevapladığı sınavların sayısı, içerik ekleme sayısı, içeriği yazdığı zaman, bir sayfa ile ilişkili bir sınava ilk kez katıldıklarında verdikleri doğru cevapların ortalama puanı, içerik eklemekten not alma arayüzünü açma sayısı ve öğrenme oturumunda harcanan süre değişkenleri kullanılmıştır. Çalışmada, Beklenti Maksimizasyonu algoritması kullanılarak kümeleme analizi gerçekleştirilmiş ve 3 öğrenen profili elde edilmiştir. Kümeler çok değişkenli istatistiksel analizler kullanılarak analiz edilmiş ve kümelerin oluşturulması için kullanılan 12 değişkenin tamamında istatistiksel olarak önemli farklılıklar belirlenmiştir. Yapılan istatistiksel analizler, bu profillerin performans açısından da farklılık gösterdiğini ortaya çıkarmıştır.

Yapılan çalışmalar incelendiğinde, çalışmaların çoğunlukla tek bir ders bağlamında ve az sayıda öğrenen ile gerçekleştirildiği görülmektedir. Çalışmalarda, daha kapsamlı analizler için veri eksikliği yaşandığı ve farklı veri kaynaklarından elde edilen verilerin kullanılması ile daha anlamlı ve genellenebilir sonuçların ortaya çıkabileceği belirtilmiştir (Amershi ve Conati, 2009; Jovanovic vd., 2012; Yukselturk ve Top, 2013). Alanyazında yapılan çalışmalardan farklı olarak bu çalışmada, farklı bölüm ve derslerde kayıtlı olan büyük bir öğrenen kitlesine ait veriler analiz edilmiştir. Böylece, alanyazındaki çalışmalara göre sonuçların genellenebilirliğinin daha yüksek olduğu değerlendirilmektedir. Buna ek olarak bu çalışmada, öğrenenlerin ÖYS kullanım verileri, öğrenme ortamındaki davranışları ve demografik verilerini içeren farklı veri kaynakları birleştirilerek öğrenen profilleri belirlenmiştir.

2.3. Açık ve Uzaktan Öğrenmede Öğrenenlerin Akademik Performanslarının Tahmin Edilmesi

Açık ve uzaktan öğrenme kurumlarında öğrenenlere ait çeşitli verilerin toplanmasıyla öğrenme süreçlerinin geliştirilmesine yönelik veri tabanlı çalışmalar yapılmaya başlanmıştır. Bu alanda yaygın olarak yapılan çalışma türlerinden biri, öğrenenlerin akademik performanslarının tahmin edilmesidir (Peña-Ayala, 2014; Romero ve Ventura, 2013). Öğrenenlerin performansları çevrimiçi öğrenme ortamı kullanımları, sınavlardan aldıkları puanlar ya da ders geçme-kalma durumları ile değerlendirilebilir. Öğrenenlerin akademik performanslarının önceden tahmin edilmesi, risk durumundaki öğrenenlerin belirlenerek erken uyarı sistemlerinin geliştirilmesine ve öneri sistemlerinin geliştirilmesine katkı sağlayabilir (Gašević vd., 2016). Öğrenme ortamındaki öğrenen davranışlarına yönelik derinlemesine bilgi kazanılması ve bu durumun öğrenenlerin akademik performanslarına nasıl etki ettiğinin anlaşılması öğrenme sürecinin desteklenmesi açısından oldukça önemlidir. Açık ve uzaktan öğrenme alanında, öğrenenlerin akademik performanslarının tahmin edilmesine yönelik yapılan çalışmalarda genellikle sınıflama ve regresyon yöntemleri kullanılmış ve çoğunlukla az sayıdaki öğrenen grupları ile çalışılmıştır.

Öğrenenlerin akademik performanslarının tahmin edilmesine yönelik alanyazındaki çalışmalar incelendiğinde, tek bir algoritma kullanılarak başarı tahmini yapıldığı gibi farklı yöntemler ve algoritmalar test edilerek eğitsel veriler için tahmin doğruluğu en yüksek algoritmaların belirlenmesine yönelik çalışmaların da bulunduğu belirlenmiştir. Bunlara ek olarak, akademik performansı tahmin etmede kullanılacak değişkenlerin belirlendiği çalışmalar da bulunmaktadır. Zacharis (2015) tarafından gerçekleştirilen çalışmada, harmanlanmış bir öğrenme ortamında öğrenenlerin akademik performanslarını tahmin etmek için Moodle ÖYS'den elde edilen veriler kullanılmıştır. Yapılan regresyon analizi sonucunda, mesaj gönderme ve okuma sayısı, içerik oluşturmaya katkı, sınavlardan alınan puanlar ve görüntülenen içerik sayısının öğrenenlerin final notundaki varyansın %52'sini tahmin edebildiği belirtilmiştir. Cerezo vd. (2016) tarafından yapılan çalışmada, 140 öğrenenin Moodle ÖYS üzerindeki etkileşim örüntüleri belirlenmiş ve bunun akademik performans ile ilişkisi incelenmiştir. Çalışmada öğrenenlerin pratik ve teorik görevler için harcadıkları süre, forumlarda geçirdikleri zaman, forum gönderilerinde kullandıkları kelime

sayısı, sistemdeki işlem sayıları ve görevi tamamlamak için geçen gün sayısı değişkenleri kullanılmıştır. Final puanları ile en yüksek ilişki düzeyine sahip değişkenler, görevler için harcanan süre, görevi tamamlamak için geçen gün sayısı ve forum gönderilerinde kullandıkları kelime sayısı olarak belirlenmiştir. Görev odaklı olan grupların diğer gruplardan akademik başarılarının daha yüksek olduğu ortaya çıkmıştır. Benzer şekilde You (2016), çevrimiçi öğrenme ortamlarında ders akademik performansını tahmin etmede kullanılabilir değişkenleri incelediği çalışmada, Blackboard ÖYS’de öğrenme sürecine devam eden 530 öğrenene ait verileri analiz etmiştir. Çalışmada, öz düzenlemeli öğrenme ile ilgili değişkenlerin başarıyı tahmin etmede önemli olduğu belirtilmiştir. Yapılan hiyerarşik regresyon analizi sonucunda, öğrenenlerin çalışma ve ödev gönderme alışkanlıklarının, derse giriş sıklıklarının ve ders ile ilgili bilgileri okumalarının akademik performanslarını %69,3 yordadığı belirlenmiştir. Yazar, toplanan değişkenler ile dönemin yarısında akademik performansın tahmin edilebileceğini vurgulamıştır.

Alanyazında akademik performansın tahmin edilmesi amacıyla farklı algoritmaların ve yöntemlerin kullanıldığı ve karşılaştırmaların yapıldığı çalışmaların sayısının diğer çalışmalara göre daha fazla olduğu görülmektedir. Kotsiantis vd. (2010), uzaktan öğrenenlerin akademik performanslarını tahmin etmek için Hellenic Açık Üniversitesi’nde Enformatik dersine kayıtlı 1.347 öğrenen üzerinde çalışma yapmışlardır. Yazarlar, bu problemin çözümü için tek bir makine öğrenmesi algoritması kullanmak yerine Naive Bayes, 1-NN ve WINNOWER algoritmalarını birleştiren bir çevrimiçi topluluk algoritması önermişlerdir. Bu algoritma ile öğrenenlerin demografik verilerine dayanan ilk tahminlerde %73 tahmin doğruluğuna, bu verilere yazılı ödev notları da dahil edildiğinde ise %82 tahmin doğruluğuna ulaşılmıştır. Zafra vd. (2011) yaptıkları çalışmada, ÖYS’de öğrenenlerin akademik performanslarını tahmin etmek için diğer çalışmalardan farklı olarak geleneksel gözetimli öğrenme yöntemleri yerine çoklu örnekle öğrenme yöntemini kullanmışlardır. Çalışma, Moodle ÖYS’de sunulan 7 farklı derse kayıtlı 419 öğrenen ile gerçekleştirilmiştir. Çalışmada öğrenenlerin tamamladıkları ödevler ve görevler için geçirdikleri süre, forumlarda okudukları ve gönderdikleri mesaj sayısı, başarılı ve başarısız oldukları sınav sayısı ve süre değişkenleri kullanılmıştır. Farklı algoritmalar kullanılarak yapılan deneysel analizler sonucunda, çoklu örnekle öğrenmeye dayalı yöntemlerin geleneksel gözetimli öğrenme yöntemlerinden daha başarılı olduğu belirtilmiştir. Geleneksel denetimli öğrenmede, en iyi

tahmin %69,76 doğruluk ile destek vektör makinesi (Support Vector Machine-SVM) algoritması ile elde edilmiştir. Farklı yöntemler kullanıldığında ise en iyi tahmin %73,57 doğrulukla PART algoritması ile elde edilmiştir.

Romero, López vd. (2013), 114 öğrenenin çevrimiçi tartışma forumlarına katılımlarını inceleyerek öğrenenlerin dersten geçme-kalma durumlarını tahmin etmeyi amaçlamışlardır. Çalışmada çeşitli veri madenciliği yöntemleri kullanılmış; seçilen değişkenlerin, kullanılan farklı sınıflama algoritmalarının ve verinin toplandığı zamanın tahmin modeli üzerindeki etkileri incelenmiştir. Öğrenenlerin akademik performanslarının tahmin edilmesinde kümeleme ve sınıflama algoritmalarının birlikte kullanılmasının daha başarılı sonuçlar verdiği, tüm değişkenler yerine amaca uygun değişkenler ile çalışılmasının tahmin modelini geliştireceği belirtilmiştir. Çalışmada 4 farklı veri seti ile analizler yapılmış ve SMO, Bayes Net, Naive Bayes Simple ve EM algoritmaları ile %70-%90 arasında tahmin doğruluğuna ulaşılmıştır. Romero, Espejo vd. (2013) çalışmalarında, Moodle ÖYS üzerinden verilen derslerdeki öğrenenlerin akademik performanslarını (Başarısız, Yüksek, İyi, Mükemmel) tahmin etmek için farklı algoritmaları test etmişler ve tahmin doğruluğu en yüksek olan algoritmayı bulmaya çalışmışlardır. Çalışmada, 7 farklı derse kayıtlı olan 438 öğrenene ait veriler analiz edilmiştir. Tamamlanan ödev sayısı, başarılı ve başarısız olunan sınav sayıları, forumlarda gönderilen mesaj sayısı ve okunan mesaj sayısı, sınav ve forumlarda harcanan toplam süre öznitelikleri girdi, final notu özniteliği ise sınıflandırıcı olarak kullanılmıştır. Gerçekleştirilen deneysel çalışmalar sonucunda, farklı durumlarda ve farklı veri setleri üzerinde en iyi sonuç veren algoritmaların farklı olduğu belirtilmiştir. Çalışmada %65 tahmin doğruluğuna ulaşılmış ve öğrenenlerin kullanım verilerinden yola çıkarak final notlarını tahmin etmenin çok zor bir görev olduğu vurgulanmıştır. Doğru sonuçlara ulaşmada ön işleme süreçlerinin önemli olduğu belirtilmiştir. Yazarlar tüm modeller arasından daha kolay anlaşılabilir ve yorumlanabilir oldukları için karar ağaçları, kural çıkarımı ve bulanık kural algoritmalarını önermişlerdir.

Hu vd. (2014), çevrimiçi öğrenme ortamlarında öğrenenlerin akademik performansını tahmin etmek için erken uyarı sistemi geliştirmişlerdir. Bu çalışmada diğerlerinden farklı olarak ders devam ederken riskli öğrenenleri tahmin etmek için erken uyarı sistemi geliştirilmiştir. Çalışma, tamamen uzaktan bir derste gerçekleştirilmiştir. Öğrenenlerin dersten geçme-kalma durumlarına yönelik tahmin modeli geliştirmek için C4.5 algoritması,

sınıflandırma ve regresyon ağacı, lojistik regresyon ve AdaBoost algoritmaları kullanılarak %95'ten yüksek tahmin doğruluğuna erişilmiştir. Deneysel değerlendirme sırasında dönem boyunca 3 farklı periyotta öğrenme etkinliklerine ait veriler toplanmıştır. Çalışmanın sonuçları, zamana bağlı değişkenlerin e-öğrenme için kritik faktörler olduğunu göstermiştir. Xing vd. (2015), genetik programlama kullanarak öğrenenlerin final notlarını tahmin etmeye çalışmışlardır. Çalışmada, tahmin modelinin daha anlaşılır ve kullanışlı olması için öğrenme analitikleri, eğitsel veri madenciliği ve İnsan Bilgisayar Etkileşimi Teorisi birlikte kullanılmıştır. Çalışmada öğrenen katılımı, Etkinlik Kuramı çerçevesinde değerlendirilmiştir. Çalışmada genetik algoritmaların geleneksel tahmin algoritmalarından daha başarılı oldukları belirtilmiştir. Bu çalışmada algoritmalar, hem genel performans tahmini hem de risk durumundaki öğrenenlerin tahmin edilmesi amacıyla kullanılmıştır. Çalışmanın sonucunda geliştirilen modelin öğretmenler tarafından da kolaylıkla anlaşılabilirliği ve yorumlanabilirliği, gerçek öğrenme ortamlarında uygulanabilirliği, öğrenenlerin performanslarını geliştirmek için somut ve bireysel öneriler sunulabilirliği belirtilmiştir. Gašević vd. (2016) öğretim koşullarının harmanlanmış öğrenme ortamlarında akademik performans (geçti-kaldı) tahminini nasıl etkilediğini incelemiştir. Çalışma, lisans düzeyindeki 9 derse kayıtlı olan 4.134 öğrenen ile gerçekleştirilmiştir. Çalışmada, Moodle ÖYS'den elde edilen kullanım verileri ve öğrenci bilgi sisteminde yer alan veriler analiz edilmiştir. Öğrenenlerin final notları çoklu lineer regresyon kullanılarak tahmin edilmiştir. Çalışmada hem ders tabanlı bir model hem de genel bir tahmin modeli geliştirilmiş ve her iki model için tahmin gücü yüksek olan değişkenlerin birbirinden farklı olduğu belirtilmiştir. Aybek ve Okur (2016), Anadolu Üniversitesi Açıköğretim Sisteminde Temel Bilgi Teknolojileri I dersini alan yaklaşık 52.000 öğrenenin final notlarını tahmin etmeyi amaçlamışlardır. Çalışmada cinsiyet, doğum tarihi, uyruk, eğitim durumu, mesleki liseden mezun olma durumu, yabancı dil durumu, engel durumu, mezuniyet derecesi, tercih sırası, mezuniyet, yerleştirme puanı ve üniversite giriş puanı değişkenleri kullanılmıştır. Yapay sinir ağları kullanılarak yapılan analizler sonucunda, ara sınav notunun final notunun en önemli yordayıcısı olduğu, çoğu demografik değişkenin ise tahmin etme gücünün yüksek olmadığı bulunmuştur.

Akademik performans tahminine yönelik alanyazın incelendiğinde, çalışmaların çoğunlukla yüz yüze eğitim veren kurumlara kayıtlı olan ve çevrimiçi ders alan öğrenenler

ya da harmanlanmış öğrenme ortamlarında gerçekleştirildiği, bununla birlikte tamamen uzaktan öğrenme ortamlarında yapılan çalışmaların sayısının ise az olduğu görülmektedir. Ek olarak, öğrenen başarısını tahmin etmek için çoğunlukla küçük gruplar üzerinde çalışılmış ve sınıflama yöntemi kullanılmıştır. Tahmin modellerinin geliştirilmesinde bir algoritma ile çalışmak yerine algoritmaların kombinasyonlarının kullanılması ile tahmin ediciliği daha yüksek modellerin oluşturulabileceği belirtilmiştir (Kotsiantis vd., 2010). Alanyazında yaygın olarak karar ağaçları, yapay sinir ağları ve Naive Bayes algoritmalarının kullanıldığı görülmektedir. Yapılan çalışmalarda genelleme yapabilmek için farklı veri kaynaklarından elde edilen ve farklı zamanlarda toplanan verilerin analiz edilmesi (Romero, Espejo vd., 2013; Romero, López vd., 2013) ve geliştirilen modelin farklı öğrenme ortamlarında test edilmesi gerektiği belirtilmiştir (Xing, 2015).

2.4. Çevrimiçi Öğrenme Ortamlarında Performans Değerlendirme Paneli Uygulamaları

Öğrenme sürecinin dijitalleşmesiyle birlikte öğrenenlere ait pek çok veri, veritabanı yapılarında depolanmaktadır. Bu veriler üzerinde yapılan analizlerle kurumlar öğrenenleri daha yakından tanıyabilmekte, iş süreçlerine yönelik düzenlemeleri gerçekleştirebilmekte ve içgörüler oluşturup geleceğe yönelik planlamalar yapabilmektedirler. Ancak büyük veri analizi ile elde edilen sonuçların öğrenenler ve öğrenenler tarafından anlamlandırılması ve yorumlanması oldukça zordur (Conde vd., 2015; Duval, 2011; Xing vd., 2015). Oysa öğrenenlerin kendileri tarafından üretilen bu verileri, kendi öğrenme süreçlerine yol gösterecek şekilde anlamlandırabilmeleri ve yorumlayabilmeleri öğrenme deneyimlerine katkı sağlayabilir. Bu zorluğun üstesinden gelmek ve verileri anlamlandırabilmek için veri görselleştirme yöntem ve teknikleri sıklıkla kullanılmaktadır (Conde vd., 2015; Duval, 2011). Veri görselleştirme, geleneksel raporlama yöntemlerinden farklı olarak görsel veya sanatsal bir yaklaşım kullanarak verilerin nasıl yansıtılacağı üzerine yapılan bir çalışma olarak tanımlanmaktadır (Yuk ve Diamond, 2014). Gürsoy (2012), veri görselleştirmenin en önemli amaçlarından birinin görsel unsurlar ve grafik arayüzler kullanarak karmaşık verilerin kolay anlaşılabilir bir hale dönüştürülmesi olduğunu belirtmektedir. Bu durum öğrenme bağlamında değerlendirildiğinde öğrenenlerin öğrenme sürecindeki davranışlarını

görselleştirmek ve raporlamak için yaygın olarak kullanılan araçlardan biri, öğrenme analitiklerine dayalı performans değerlendirme panelleridir (Jivet vd., 2017; Kemsley, 2020; Knight vd., 2015; Roberts vd., 2017). Öğrenme analitiklerine dayalı performans değerlendirme panelleri (PDP), çevrimiçi öğrenme ortamlarındaki öğrenme süreçleri ile ilgili farklı göstergelerin görselleştirilmesiyle öğrenenlere ilerleme durumları ve öğrenme davranışlarına ilişkin bilgilerin bütüncül olarak sunulmasına olanak sağlayan bir araç olarak tanımlanabilir (Park ve Jo, 2015; Ramos-Soto vd., 2017; Schwendimann vd., 2017). Bu öğrenme analitiği aracı, öğrenenlerin güncel öğrenme durumları hakkında bilgi sahibi olmasına, önceki dönemler ile karşılaştırma yapabilmesine, durumlarına uygun olarak geri bildirimler ve yönergeler gönderilmesine olanak sağlamaktadır (Yoo vd., 2015). Kişisel bilişim uygulaması olarak ele alınabilecek PDP'ler (Li vd., 2010), aynı zamanda sayısallaştırılmış benlik kavramı ile de ilişkilidir (Duval ve Verbert, 2012). Kişisel bilişim, kişisel geçmişin takip edilmesi ve analizi için araçlar sağlayarak kullanıcıların kendi bilgilerini geliştirmelerine olanak tanımaktadır (Verbert vd., 2013). Sayısallaştırılmış benlik yaklaşımında ise kullanıcıların dijital ortamda kaydedilen verilerine dayalı olarak izlerini toplamak ve deneyimlerini geliştirmek için bu izlerin kullanılmasına odaklanılmaktadır (Duval ve Verbert, 2012).

Öğrenme analitiklerinin normatif boyutunda değerlendirilebilecek PDP'ler; eğitim alanında öğrenme sürecinin geliştirilmesi, iyileştirilmesi ve karar süreçlerinin desteklenmesi açısından oldukça önemli bir role sahiptir. Bu durum özellikle öğretene ve öğrenenlerin fiziksel olarak ayrı yerlerde olduğu çevrimiçi öğrenme ortamlarında ön plana çıkmaktadır (Park ve Jo, 2019). PDP araçları öğrenenlerin çevrimiçi öğrenme deneyimleri ve davranışları hakkında bilgi sunar, öz düzenlemeli öğrenme becerilerinin geliştirilmesine destek olur, öz yansıtma ve öz farkındalığı teşvik eder ve öğrenenleri hedeflerine ulaşmaları için motive eder (Eynon, 2015; Matcha vd., 2019; Naranjo vd., 2019; Park ve Jo, 2019; Roberts vd., 2017; Verbert vd. 2013). Bu açıdan değerlendirildiğinde PDP'ler, öğrenenler için üstbilişsel araçlar olarak kullanılma potansiyeline sahiptir (Bodily vd., 2018; Charleer vd., 2016; Chen vd., 2019; Eynon, 2015). PDP'ler öğrenenleri desteklemek amacıyla öğrenen-içerik etkileşimini izlemek, anlamlandırmak ve raporlamak için kullanılabilir (Bodily vd., 2018). Bu bağlamda PDP'ler öğrenme yönetim sistemlerinin faydalarını artırmak için bir araç olarak kullanılabilir (Verbert vd., 2020). Etkili bir PDP, öğrenenlerin öz düzenleme davranışlarını ve nihayetinde

öğrenme davranışlarını ve sonuçları etkileyecektir (Bodily vd., 2018). PDP'ler sayesinde öğrenenler öğrenmeye harcayacakları zamanı daha iyi planlayabilirler, çalışma süreçlerini yönetebilirler ve öğrenme hedeflerine ulaşabilirler (Verbert vd., 2020). Bununla birlikte öğrenenler güçlü ve zayıf yanlarını belirleyebilir ve öğrenme stratejilerine ilişkin içgörü kazanabilirler (Akçapınar ve Uz Bilgin, 2020; Jivet vd., 2020). Aynı zamanda bu araçlar, öğrenme sürecini öğrenenler için görünür hale getirerek kişiselleştirilmiş öğrenme süreçlerini desteklemek için kullanılabilir (Kokoç ve Altun, 2019; Ulfa vd., 2019).

e-öğrenmenin yaygınlaşması, çevrimiçi öğrenme platform kullanımının artması ve öğrenme analitiği alanındaki gelişmelere paralel olarak yükseköğretim düzeyinde PDP kullanımı da yaygınlaşmıştır (Love vd., 2021; Park ve Jo, 2019; Pelletier vd., 2021; Roberts vd., 2017). Purdue University tarafından geliştirilen Sinyal Projesinde, trafik ışıkları ile öğrenen başarısına yönelik bilgi verilmiştir (Sclater vd., 2016). Buna ek olarak, kişiselleştirilmiş geri bildirim mesajları gibi erken uyarılar ile öğrenenlerin motivasyon, başarı ve derse devam etme oranlarının yükseldiği görülmüştür (Arnold ve Pistilli, 2012; Sclater vd., 2016). Carnegie Mellon University'de geliştirilen PDP'de ise, Sinyal Projesi'ne benzer renklerle öğrenenlerin dersin hedeflerine ne ölçüde ulaştığı gösterilmiştir (Dolla' r ve Steif, 2012). Bu çalışmada öğrenenlerin hareketleri ve performansına yönelik daha detaylı bilgiler sunulmuştur. Open University, öğrenenlere dersteki performanslarını geliştirmelerine yardımcı olmak amacıyla kişiselleştirilmiş bir PDP sunmaktadır (Open University, 2018). Bu panelde sanal öğrenme ortamı etkileşim grafiği, puanlar ve tahminler, tahmin geçmişi, benzer öğrenenler grafiği ve çalışma öneri aracı yer almaktadır (Rets vd., 2021). Michigan University'de Öz Düzenlemeli Öğrenme Teorisine dayalı olarak geliştirilen My Learning Analytics aracı öğrenenlere sunulmaktadır (Kia vd., 2020). Bu panelde öğrenenlerin içerik erişimleri, görev planlamaları ve not dağılımları yer almaktadır. Bu panel, akademik performansla önemli ölçüde ilgili olan motivasyon ve öz düzenlemeli öğrenmeyi desteklemek için tasarlanmıştır (Love vd., 2021). Paneli kullanan öğrenenlerin %66'sı çalışma ve ders etkinliklerini planlama alışkanlıklarında değişim olduğunu belirtmiştir (Love vd., 2021).

PDP geliştirme ve öğrenme sürecindeki etkileri üzerinde pek çok çalışma yapılmıştır. Aguilar vd. (2021), PDP kullanımı ile motivasyon ve öz düzenlemeli öğrenme arasındaki ilişkiyi inceledikleri çalışmalarında öğrenenlerin 7 hafta gibi kısa bir sürede dahi

motivasyonlarında ve öz-düzenlemeli öğrenme süreçlerinde değişiklik olabileceği sonucuna ulaşmışlardır. Aljohani vd. (2019) tarafından geliştirilen AMBA aracı ile öğrenenlerin çevrimiçi etkinliklerine yönelik istatistiksel, metinsel ve görsel geri bildirim verilmiştir. Gerçekleştirilen uygulama sonucunda, AMBA aracıyla etkileşim kuran öğrenenlerin öğrenme yönetim sistemine ve tartışma panosuna daha sık eriştikleri ve final notlarının diğerlerinden daha yüksek olduğu ortaya çıkmıştır. Benzer olarak, Kokoç ve Altun (2019) da PDP'ler ile etkileşime giren öğrenenlerin akademik başarılarının daha yüksek olduğu sonucuna ulaşmışlardır. Jivet (2021) de MOOC'larda PDP ile daha fazla etkileşime giren öğrenenlerin mezun olma olasılıklarının daha yüksek olduğunu vurgulamıştır. Ulfa vd. (2019), PDP'lerin öz düzenlemeli öğrenmeye destek olduğunu ve öğrenenlerin kendi öğrenme süreçlerini takip edebildikleri için e-öğrenme etkileşimlerinin yükseldiğini belirlemişlerdir. Akçapınar ve Uz Bilgin (2020), öğrenme analitiklerine dayalı oyunlaştırılmış bir gösterge paneli tasarlamışlar ve bu aracın öğrenenlerin çevrimiçi öğrenme ortamlarındaki bağlılıklarına etkisini araştırmışlardır. Yazarlar, gösterge paneline oyunlaştırma öğeleri eklemenin öğrenen bağlılığını istatistiksel olarak anlamlı derecede artırdığı sonucuna ulaşmışlardır. Bodily vd. (2018) tarafından geliştirilen PDP'de içerik öneri paneli ve beceri öneri paneli olmak üzere 2 farklı panel yer almıştır. Uygulamanın ardından öğrenenlerin PDP'lere yönelik algılarının olumlu olduğu ancak kullanım düzeylerinin düşük olduğu belirlenmiştir. Chen vd. (2019) öz düzenlemeli öğrenmeyi geliştirmek için bilgi izleme ve strateji kullanım panosu olmak üzere 2 panel tasarlamışlardır. Naranjo vd. (2019) tarafından bulut tabanlı ve açık kaynaklı olarak hem öğretene hem de öğrenenlere yönelik CloudTrail Tracker isimli bir PDP geliştirilmiştir. Bu araçta öz düzenlemeli öğrenmeyi desteklemek için ilerleme durumu ve bekleyen eylemler yer almaktadır. Kim vd. (2016), bir PDP aracılığıyla geri bildirim alan öğrenenlerin, geri bildirim almayanlara göre önemli ölçüde daha yüksek puanlar aldığını belirlemiştir. Bu çalışmaların bulgularından farklı olarak Khan ve Pardo (2016) yaptıkları çalışmada, öğrenenlerin PDP görüntüleme sayısı ile ara sınav puanları arasında anlamlı bir ilişki bulunmadığını belirtmişlerdir. Brouwer vd. (2016) ise, PDP sunulan öğrenen grubunda önemli ölçüde daha yüksek bir performans olduğunu, ancak PDP kullanım sıklığı ile performans arasında istatistiksel olarak anlamlı bir ilişki olmadığını belirttiler. Govaerts vd. (2012) tarafından geliştirilen Student Activity Meter (SAM) aracında öğrenenlerin dersteki ilerleme durumu görselleştirilmiştir. Bu araç ile hem

öğretenlere hem de öğrenenlere, öğrenenlerin öğrenme ortamında hareketlerine ve nasıl çalıştıklarına dair öz yansıtma ve farkındalık kazandırılması amaçlanmaktadır (Govaerts vd., 2012). SAM, farklı öğrenme yönetim sistemlerinde kullanılabilen ve özelleştirmeler yapılabilir. Bunlara ek olarak çevrimiçi ya da hibrit öğrenme ortamlarına yönelik olarak LOCO-Analyst (Ali vd., 2012), Moodle Dashboard (Podgorelec ve Kuhar, 2011), GLASS (Leony vd., 2012), CALMSystem (Kerly vd., 2007), StepUp! (Santos Odriozola vd., 2013), iTree (Nakahara vd., 2005) ve SNAPP (Dawson vd., 2010) gibi pek çok araç geliştirilmiştir.

Alanyazında yer alan çalışmalar incelendiğinde PDP'ye yönelik pek çok araştırma yapıldığı görülmektedir. PDP kullanımının öğrenenlerin e-öğrenme içeriklerine erişim oranları, akademik performans, etkileşim, motivasyon, bağlılık ve derse devam etme durumlarının yükseldiği, öz düzenlemeli öğrenme becerilerinin ve üstbilişin geliştirilmesine destek olduğu dahası artırdığı sonuçlarına ulaşılmıştır (Aljohani vd., 2019; Arnold ve Pistilli, 2012; Kokoç ve Altun, 2019; Love vd., 2021; Selater vd., 2016). PDP'lerin öğrenme sürecinde kullanımının pek çok faydası olmakla birlikte PDP erişimini doğrudan içerik erişimi ve akademik performans ile ilişkilendirmek hatalı sonuçlara neden olabilir (Brouwer vd., 2016). Burada öğrenenlerin sistem ve içerik kullanımına yönelik davranış değişikliklerini akademik performans ile birlikte takip etmek PDP'lerin etkisinin daha doğru bir şekilde belirlenmesini sağlayabilir. Yükseköğretim kurumları tarafından PDP'lerin artan kullanımına rağmen, öğrenenlerin bu aracı nasıl değerlendirdiği ve bu araca nasıl tepki verdiği konusunda araştırmalara gereksinim duyulmaktadır (Rets vd., 2021). Ayrıca PDP'lerin nasıl oluşturulacağına dair çok sayıda araştırma olmasına rağmen, öğrenenlerin bu tür grafiksel görüntüleri nasıl yorumladıkları hakkında da araştırmaların yetersiz olduğu görülmektedir (Jivet vd., 2020). Bunlara ek olarak, PDP araçlarının öğretme ve öğrenme sürecini nasıl desteklediği ve etkilediği konusunda çalışmaların yapılması gerekmektedir (Park ve Jo, 2019). PDP'lerin çoğu, öğretmenler ya da karar vericiler için geliştirilmiştir, öğrenenlere yönelik az sayıda PDP bulunmaktadır (Kokoç ve Altun, 2019; Rets vd., 2021; Schwendimann vd., 2017). Yöntemsel açıdan değerlendirildiğinde çalışmaların çoğunda nicel yöntemler kullanıldığı ancak bu bulguların nitel yöntemlerle desteklenmesi ve doğrulanması gerektiği belirtilmektedir (Rets vd., 2021). Buna ek olarak, çoğu makalede PDP tasarımının nihai durumu ve değerlendirme süreçleri tartışılırken, PDP oluşturma

sürecindeki tasarım ve geliştirme adımları dışarıda bırakılmaktadır (Bodily ve Verbert, 2017). Ancak, nihai üründen önce gerçekleşen yinelemeli tasarım ve geliştirme süreci hakkında şeffaf olmak, PDP geliştirme süresini azaltabilir, PDP etkinliğini artırabilir ve mevcut alanyazına katkı sağlayabilir (Bodily ve Verbert, 2017). Aynı zamanda çalışmaların çok azında veri madenciliği ile analizlerin yapıldığı belirlenmiştir (Bodily ve Verbert, 2017). Bunlara ek olarak, alanyazındaki çalışmalar incelendiğinde PDP'lerin genellikle az sayıda öğrenenin yer aldığı dersler kapsamında yapıldığı görülmektedir. Ancak bu çalışmaların daha büyük ölçeklerde ve heterojen kitleler üzerindeki etkisinin de araştırılması gerekmektedir (Jivet vd., 2020). PDP'lerin çalışma başarısını desteklemedeki etkililiğine yönelik büyük ölçekli kanıtlar hala eksiktir (Ifenthaler ve Yau, 2020). Ayrıca, genelleştirilebilir ve aktarılabilir bulgular üretmek için gelecekteki araştırmalarda büyük ölçekli, boylamsal ve deneysel araştırmalara odaklanılması gerektiği ifade edilebilir (Ifenthaler ve Yau, 2020).

PDP'lerin temel amacı, öğrenmeyi geliştirmek olmalıdır (Klerx vd., 2017). Öğrenme; bellek, düşünme, üstbilgi ve yansıtma kullanımını içeren içsel bir süreç olarak tanımlanabilir (Anderson, 2008). Bu bağlamda ele alındığında öğrenenlere yönelik PDP'lerin birincil amacının farkındalık veya yansıtma olması ilginçtir (Bodily ve Verbert, 2017). Öğrenenlerin öğrenme sürecindeki çabalarının farkında olmaları oldukça önemlidir (Charleer vd., 2016). Ancak, öğrenenleri sadece bilinçlendirmek yeterli değildir (Jivet vd., 2020; Matcha vd., 2019). PDP'ler bilişsel, davranışsal veya duygusal yetkinlikleri geliştirmek için farkındalık ve yansıtmayı kullanarak daha geniş bir amaca sahip olmalıdır (Matcha vd., 2019). PDP'ler pasif bilgi gösterimleri olmanın ötesine geçmeli ve öğrenenlerin harekete geçmelerini sağlayan eylem desteğini de içermelidirler (Jivet vd., 2020). Bu bağlamda ele alındığında erken müdahale uygulamaları, öğrenenlerin önceden bilgilendirilmesine ve böylece eyleme geçmesine destek olabilir. Bunu gerçekleştirmek için geri bildirim bileşeni kullanılabilir. Öğrenenlere öğrenme etkinliklerine katılımları ve performansları hakkında doğrudan geri bildirim sağlamak, öğrenmeyi desteklemeye ve iyileştirmeye katkı sunabilir (Jivet vd., 2020; Corrin ve De Barba, 2015). Geri bildirim, öz düzenlemeli öğrenme sürecinin en önemli unsurlarından biridir (Matcha vd., 2019). Ancak yapılan çalışmalar incelendiğinde PDP'lerde çoğunlukla geri bildirim bileşeninin olmadığı görülmüştür. Bununla birlikte öğrenenlere yönelik raporlama sistemlerinin önerileri ve görsel unsurları içermesi yaygınken bunları aynı sistem içine dahil etmek yaygın değildir (Bodily vd., 2018). Bodily ve Verbert (2017)

tarafından PDP'lere yönelik eğilimlerin incelendiđi alıřmada, geliřtirilen araların yaklaşık %20'sinin hem öneri bileřenini hem de görsel unsurları ierdiđi ortaya ıkmıřtır. Bu nedenle, öneri ve geri bildirim bileřenini ieren PDP'lerin tasarlanmasına ve bunların etkilerinin belirlenmesine yönelik alıřmalara ihtiya duyulduđu belirtilebilir.

3. YÖNTEM

Bu bölümde araştırma soruları bağlamında araştırma modeli, çalışma kümesi, veri kaynakları, veri toplama araçları ve araştırma süreci açıklanmıştır.

3.1. Araştırma Modeli

Bu çalışmanın amacı, kitlesel uzaktan eğitim uygulamasında öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin belirlenmesi, öğrenen profillerinin belirlenmesi, akademik performanslarına yönelik tahmin modeli geliştirilmesi ve tasarımı PDP'nin öğrenme sürecindeki etkilerinin incelenmesidir. Bu kapsamda örüntülerin belirlenmesi ve kural çıkarımı, öğrenen profillerinin belirlenmesi ve akademik başarının tahmin edilmesi süreçlerinde makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. PDP'nin öğrenme sürecindeki etkilerinin belirlenmesi için ise deney tasarımı gerçekleştirilmiştir. Deney ve kontrol grupları arasında oturum açma sayıları, oturum açtıkları gün sayıları, öğrenme malzemelerine erişim sayıları ve akademik performanslarındaki farkların belirlenmesi için bağımsız örneklem t-testi yapılmıştır. Son olarak PDP'ye yönelik görüşlerin ve memnuniyet düzeyinin belirlenmesi amacıyla çevrimiçi anket uygulanmış ve yanıtlar değerlendirilmiştir. Çalışmada araştırmanın gerçekleştirilmesi, Açıköğretim Sistemi veritabanlarındaki verilerin kullanılması, PDP ve anket uygulaması işlemleri Etik Kurul ve kurum izni alınarak gerçekleştirilmiştir (EK-11, EK-12). Çalışma kapsamında gerçekleştirilen süreç, Görsel 3.1'de özetlenmiştir.

	Tanımlayıcı Analitik		Tahmin Edici Analitik	Normatif Analitik		
Amaç	Öğrenme Malzemeleri Kullanım Örüntülerinin Belirlenmesi	Öğrenen Profillerin Belirlenmesi	Akademik Performans Tahmin Modelinin Geliştirilmesi	PDP Geliştirilmesi ve Uygulanması	PDP'nin Öğrenme Sürecindeki Etkilerinin Belirlenmesi	Öğrenenlerin PDP'ye Yönelik Görüşlerinin Belirlenmesi
Öğretim Yılı ve Dönem	2019-2020 öğretim yılı güz dönemi	2019-2020 öğretim yılı güz dönemi	2019-2020 öğretim yılı güz dönemi	2020-2021 öğretim yılı bahar dönemi	2020-2021 öğretim yılı bahar dönemi	2020-2021 öğretim yılı bahar dönemi
Ders / Program	86 farklı program	86 farklı program	BIL101U dersi	BIL102U dersi	BIL102U dersi	BIL102U dersi
Çalışma Kümesi	602.372 öğrenen	597.164 öğrenen	56.810 öğrenen	Deney Grubu: 13.377 Kontrol Grubu: 13.376	Deney Grubu: 13.377 Kontrol Grubu: 13.376	451 öğrenen
Yöntem	<ul style="list-style-type: none"> Makine Öğrenmesi <ul style="list-style-type: none"> Gözetimsiz Öğrenme <ul style="list-style-type: none"> Birliktelik Kuralları 	<ul style="list-style-type: none"> Makine Öğrenmesi <ul style="list-style-type: none"> Gözetimsiz Öğrenme <ul style="list-style-type: none"> Kümeleme Analizi 	<ul style="list-style-type: none"> Makine Öğrenmesi <ul style="list-style-type: none"> Gözetimli Öğrenme <ul style="list-style-type: none"> Sınıflandırma Derin Öğrenme 	Deney tasarımı	Bağımsız örneklem t-testi	Çevrimiçi anket yanıtlarının analizi edilmesi
Algoritmalar	<ul style="list-style-type: none"> Apriori CARMA FP-Growth 	<ul style="list-style-type: none"> TwoStep k-Means 	<ul style="list-style-type: none"> Generalized Linear Model Logistic Regression Naive Bayes Fast Large Margin Decision Tree Random Forest Gradient Boosted Trees Deep Learning 			

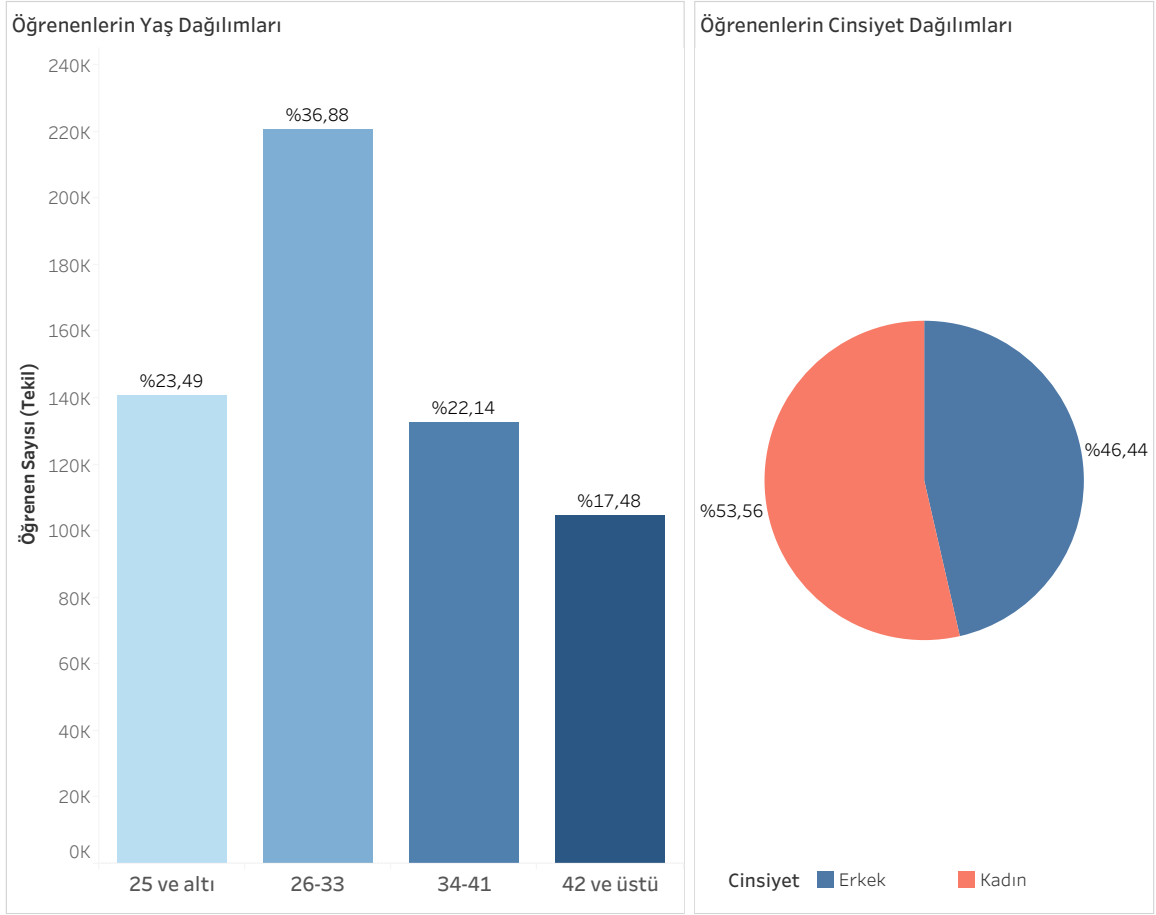
Görsel 3.1. Çalışmanın aşamaları

3.2. Çalışma Kümesi

Araştırmanın çalışma kümesi, araştırma soruları bağlamında farklılaşmaktadır. Çalışma kümesi bu kapsamda açıklanmıştır.

3.2.1. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi çalışma kümesi

Öğrenenlerin ÖYS davranışlarındaki örüntülerin ortaya çıkarılması amacıyla öğrenenlerin zaman bazlı öğrenme malzemeleri kullanım verilerinin yer aldığı bir tablo oluşturulmuştur. Örüntülerin belirlenmesi çalışması, 2019-2020 öğretim yılı Güz döneminde, 86 farklı programa kayıtlı olan 602.372 öğrenene ait veriler analiz edilerek gerçekleştirilmiştir. Bu çalışmadaki veriler, 30 Eylül 2019-20 Ocak 2020 tarihleri arasında yapılan faaliyetleri içermektedir. Öğrenenlerin yaş ve cinsiyet dağılımları, Şekil 3.1'de verilmiştir.



Şekil 3.1. Örüntülerin belirlenmesi çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları

Şekil 3.1 incelendiğinde öğrenenlerin büyük çoğunluğunun 26-33 yaş arasında olduğu ve yaklaşık %60'ının 18-33 yaş aralığında olduğu görülmektedir. Bunun yanı sıra, öğrenenlerin %50'den fazlası kadın olmakla birlikte kadın ve erkek öğrenen sayılarının birbirine yakın olduğu belirtilebilir. Bu grafiğe, cinsiyet ve yaş verisi olmayan öğrenenler dahil edilmemiştir.

3.2.2. Çevrimiçi öğrenme ortamında öğrenen profillerinin belirlenmesi çalışma kümesi

Öğrenen profillerinin belirlenmesi amacıyla öğrenenlerin malzeme kullanım verilerinin, demografik özelliklerinin, bölüm ve sınav notlarının yer aldığı bir tablo oluşturulmuştur. Öğrenen profillerinin belirlenmesi çalışması, 2019-2020 öğretim yılı Güz


döneminde, 86 farklı programa kayıtlı olan 597.164 öğrenene ait veriler analiz edilerek gerçekleştirilmiştir. Bu çalışmadaki veriler, 30 Eylül 2019-20 Ocak 2020 tarihleri arasında yapılan faaliyetleri içermektedir.

Örüntülerin ve profillerin belirlenmesi için hazırlanan tablolar aynı iki tablodan elde edilmiştir. Dolayısıyla çalışma kümeleri birbirine benzer özellikler göstermektedir. Profillerin belirlenmesi çalışma kümesindeki öğrenenlerin yaş, cinsiyet ve genel not ortalama dağılımları Şekil 3.1’de yer almaktadır. Profillerin belirlenmesi çalışma kümesindeki öğrenenlerin %54’ü kadın, %46’sı ise erkektir. Öğrenenlerin %37’si 26-33, %24’ü 25 ve altı, %22’si 34-41 ve %17’si 42 yaş ve üstü gruplarındadır.

Profillerin belirlenmesi çalışma kümesindeki öğrenenlerin %64’ü çalışmakta, %21’i öğrenci, %15’i ise çalışmamaktadır. Öğrenen sayısının en fazla olduğu bölümler Adalet, İşletme, İlahiyat ve Sosyolojidir. Öğrenenlerin %47’si ikinci üniversite kapsamında kaydolmuştur.

3.2.3. Akademik performans tahmin modelinin geliştirilmesi çalışma kümesi

Öğrenenlerin akademik performanslarının tahmin edilmesi çalışması, 2019-2020 öğretim yılı Güz döneminde BIL101U dersinde gerçekleştirilmiştir. Tahmin modelinin geliştirilmesi amacıyla öğrenenlerin malzeme kullanım verilerinin, demografik özelliklerinin, bölüm ve sınav notlarının yer aldığı bir tablo oluşturulmuştur. Tahmin modelinin geliştirilmesi çalışması, BIL101U dersine kayıtlı olan 56.810 öğrenene ait veriler analiz edilerek gerçekleştirilmiştir. Bu çalışmadaki veriler, 30 Eylül 2019-20 Ocak 2020 tarihleri arasında yapılan faaliyetleri içermektedir. Öğrenenlerin yaş ve cinsiyet dağılımları, Şekil 3.2’de verilmiştir.



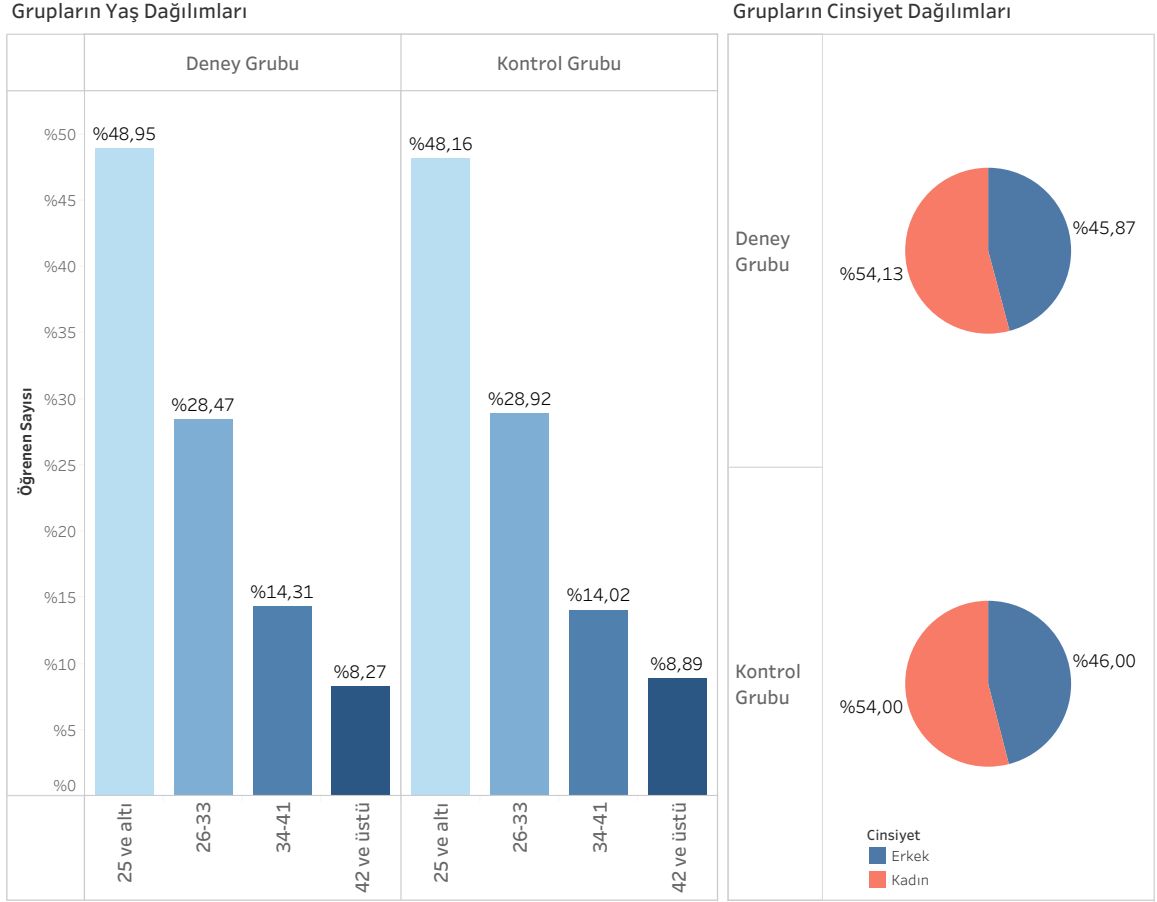
Şekil 3.2. Tahmin modelinin geliştirilmesi çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları

Tahmin modelinin geliştirilmesi çalışmasındaki öğrenenlerin %70'e yakını 18-33 yaş aralığındadır. Öğrenenlerin %58'i erkek, %42'si ise kadındır. Diğer çalışma kümelerinden farklı olarak buradaki erkek öğrenen oranı, kadın öğrenen oranından daha yüksektir.

3.2.4. Öğrenme analitikleri tabanlı performans değerlendirme paneli uygulaması çalışma kümesi

PDP uygulaması, 2020-2021 öğretim yılı Bahar döneminde BIL102U dersinde gerçekleştirilmiştir. Bu süreçte öğrenenler deney ve kontrol grubu olarak 2 gruba ayrılmıştır. Deney grubundaki öğrenenlere PDP uygulaması sunulmuş, kontrol grubundaki öğrenenlere sunulmamıştır. Deney grubunda 13.377, kontrol grubunda ise 13.376 öğrenen

bulunmaktadır. Bu çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları, Şekil 3.3'te verilmiştir.

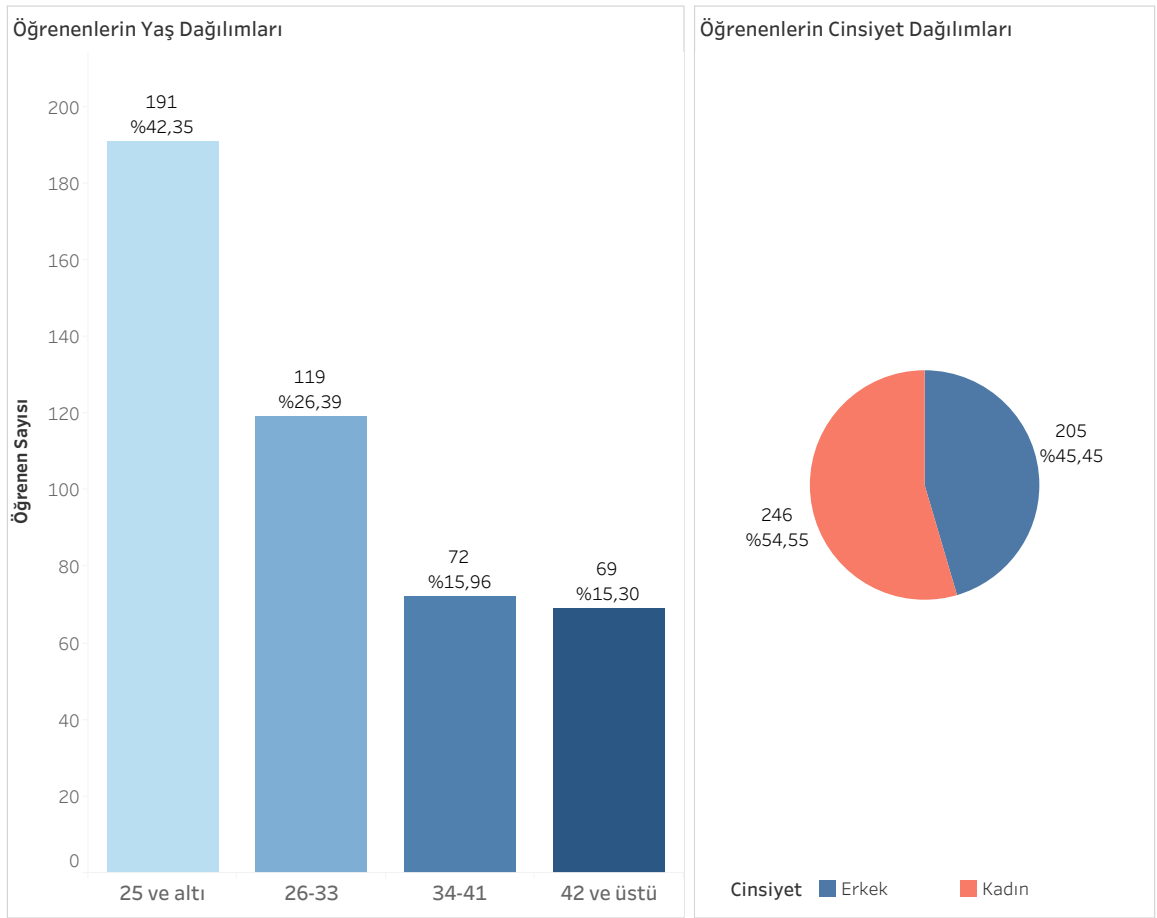


Şekil 3.3. PDP uygulaması çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları

Şekil 3.3 incelendiğinde deney ve kontrol grubundaki öğrenenlerin yaş ve cinsiyet dağılımları açısından birbirine benzer özelliklerde oldukları görülmektedir. Her iki gruptaki öğrenenlerin %54'ü kadın, %46'sı ise erkektir. Öğrenenlerin yaklaşık %49'u 25 yaş ve altında, %29'u 26-33, %14'ü 34-41 ve %8'i 42 yaş ve üstündedir.

3.2.5. Öğrenme analitikleri tabanlı performans değerlendirme paneline yönelik öğrenen görüşlerinin belirlenmesi çalışma kümesi

2020-2021 öğretim yılı Bahar dönemi boyunca BIL102U dersinde deney grubundaki öğrenenlere PDP uygulaması sunulmuştur. Dönemin sonunda öğrenenlerin PDP'ye yönelik görüşlerinin ve memnuniyet düzeylerinin belirlenmesi amacıyla bir anket uygulanmıştır. Bu anketi, 451 öğrenen yanıtlamıştır. Anketi yanıtlayan öğrenenlerin yaş ve cinsiyet dağılımları Şekil 3.4'te verilmiştir.



Şekil 3.4. Anket çalışma kümesindeki öğrenenlerin yaş ve cinsiyet dağılımları

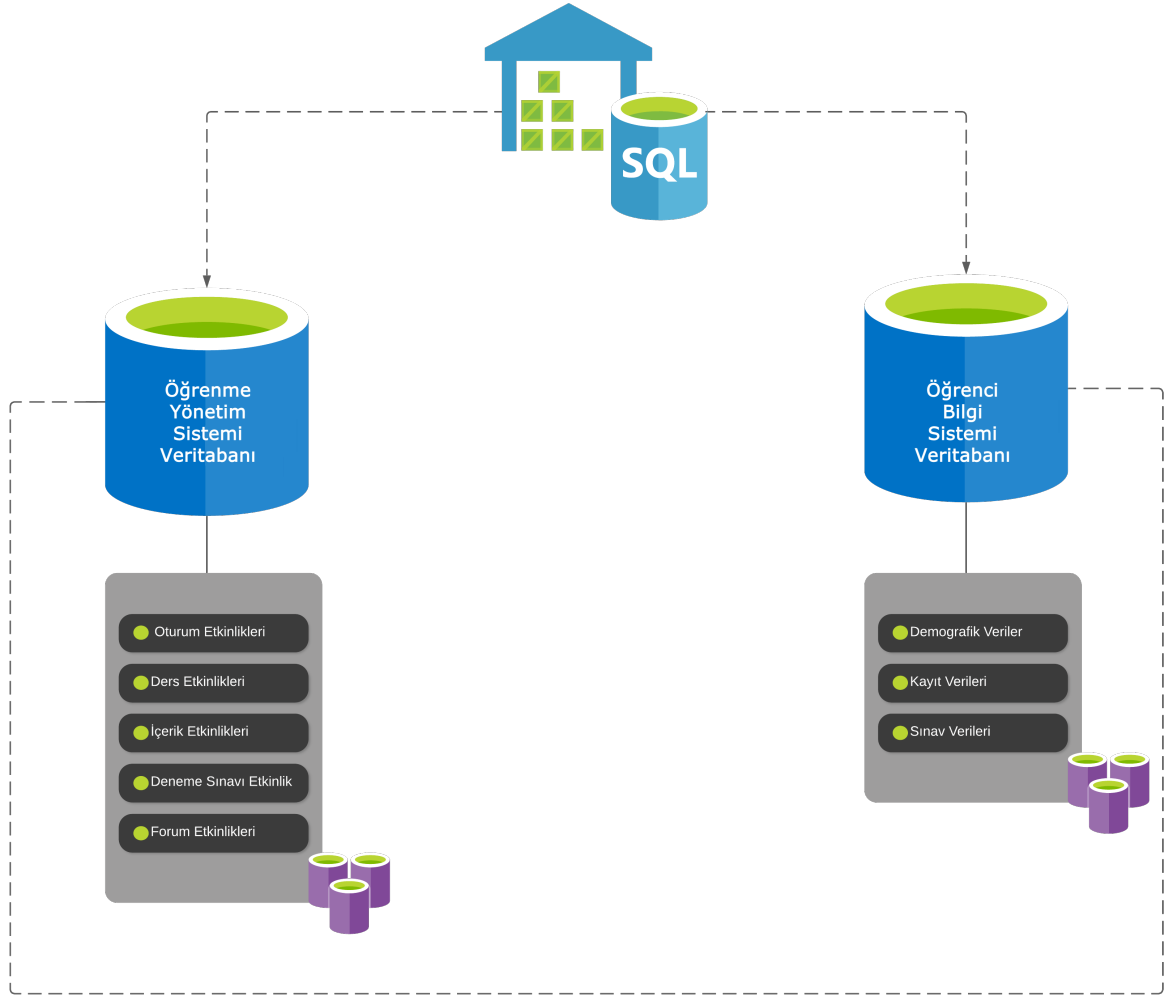
Anketi yanıtlayan öğrenenlerin %55'i kadın, %45'i ise erkektir. Bu öğrenenlerin %42'si 25 yaş ve altı, %26'sı 26-33 yaş aralığında, %16'sı 34-41 yaş aralığında ve %15'i 42 yaş ve üzerindedir.

3.3. Veri Kaynakları ve Veri Toplama Araçları

Çalışmada öğrenenlerin öğrenme yönetim sistemi kullanımları, demografik özellikleri ve öğrencilik durumlarına ilişkin veriler, veri ambarı oluşturularak bir araya getirilmiştir. Buna ek olarak, Araştırma Sorusu 5 kapsamında öğrenenlere anket uygulanmıştır. Bu bölümde, veri ambarı yapısı ve anket hakkında bilgiler açıklanmaktadır.

3.3.1. Çalışma veri ambarı

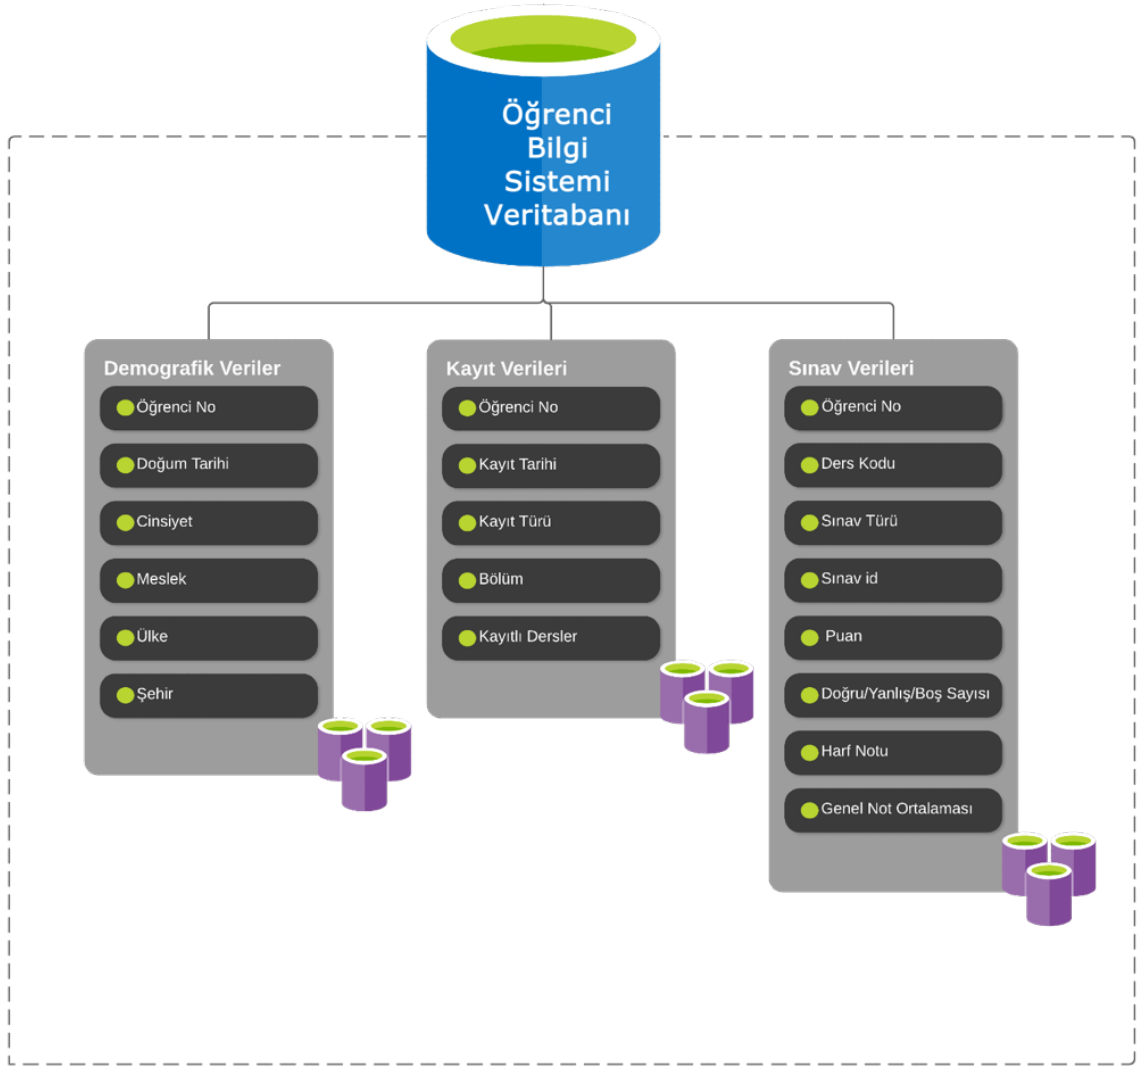
Çalışmada veri madenciliği, makine öğrenmesi, veri modellemesi ve analiz süreçlerinde kullanılacak veriler, veri ambarında bir araya getirilmiştir. Veri ambarı, Öğrenci Bilgi Sistemi ve Öğrenme Yönetim Sistemi veritabanlarından beslenmektedir. Öğrenci Bilgi Sistemi için MSSQL Server 2018 veritabanı kullanılmaktadır. MSSQL, Microsoft tarafından geliştirilen ilişkisel bir veritabanı yönetim sistemidir. Anadolium eKampüs sistemindeki öğrenen hareketlerine yönelik veriler ise SQL Server 2017 veritabanında tutulmaktadır. Veri ambarına hizmet etmek üzere MSSQL Server 2017 veritabanı işe koşulmaktadır. Veri ambarının çalışacağı işletim sistemi, Windows Server 2019'dur. Anadolu Üniversitesi tarafından belirlenmiş olan güvenlik ölçütleri kapsamında, veri ambarı sunucusu dış ortama kapalı olarak sadece yerel ağdan erişebilecek şekilde kurgulanmıştır. Aynı zamanda sistem, kötü niyetli saldırılara karşı bir güvenlik duvarı arkasında çalıştırılmaktadır. Çalışmada kullanılan veri ambarında araştırma soruları bağlamında farklı tablolar oluşturulmuştur. Yapılan tüm işlemlerin ardından veri ambarında, 44 tablo yer almaktadır. Veri ambarı, yaklaşık 500 GB boyutundadır. Görsel 3.2'de veri ambarı yapısı görselleştirilmiştir.



Görsel 3.2. Çalışmanın veri ambarı yapısı

3.3.1.1. Öğrenci Bilgi Sistemi veritabanı

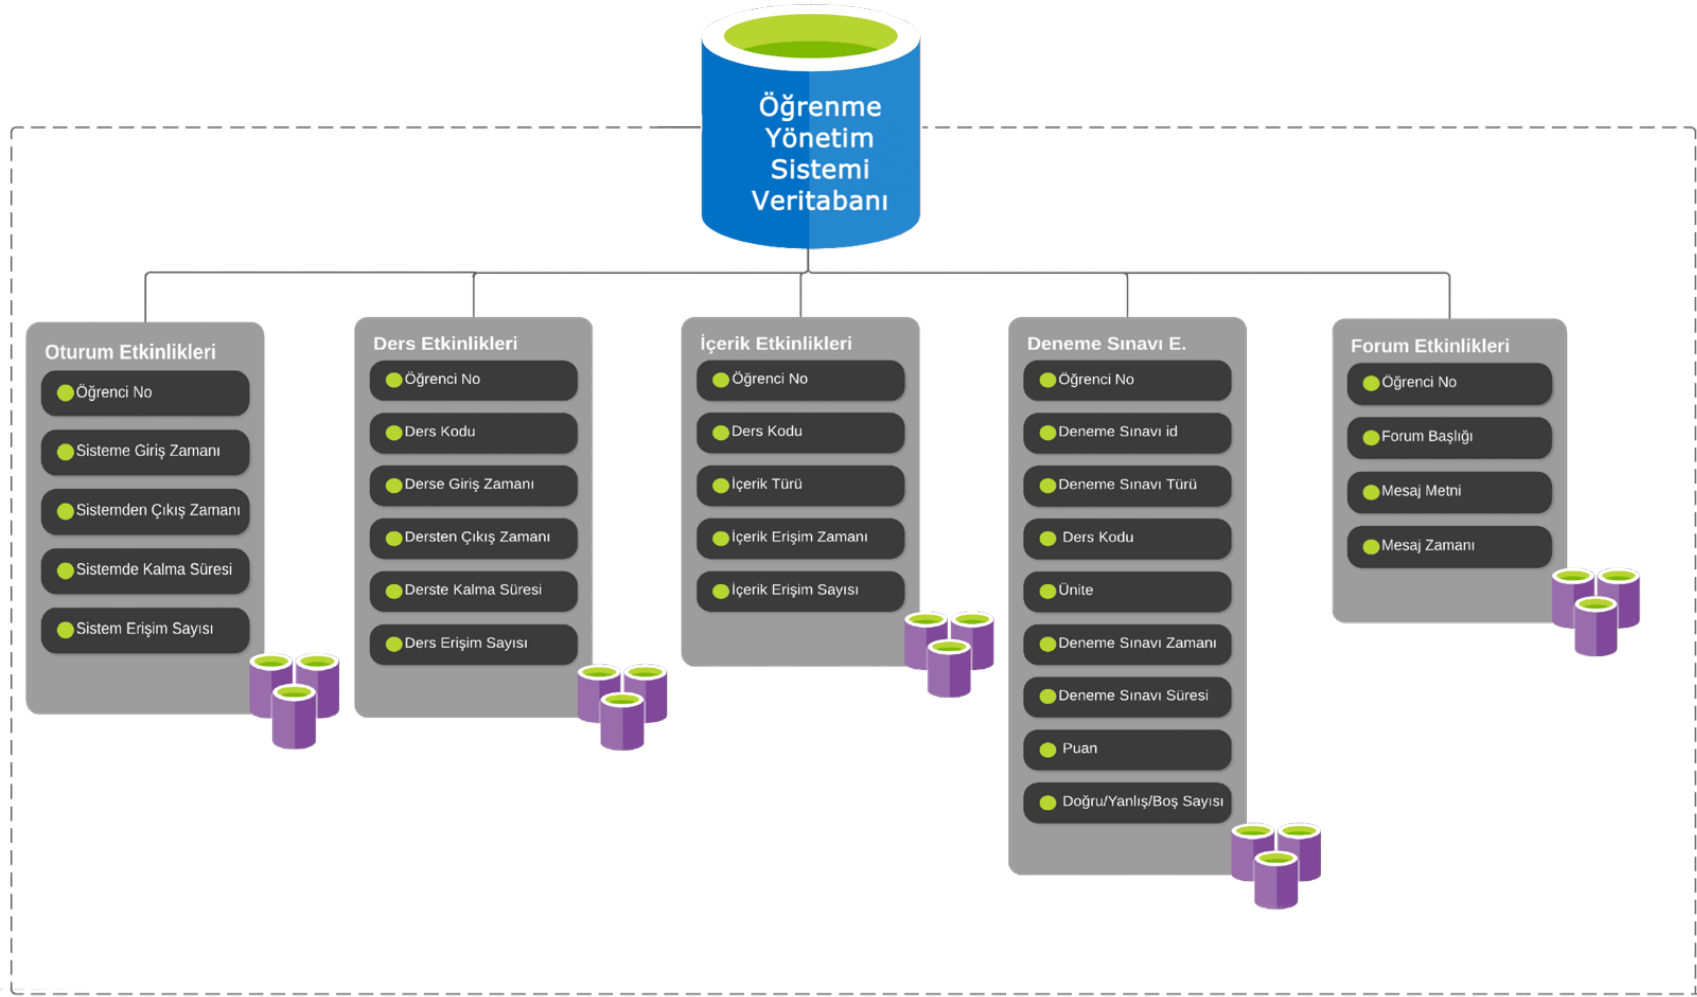
Açıköğretim Sistemindeki öğrenenlerin demografik verileri, bölüm, kayıtlı oldukları dersler, sınav ve not verileri Öğrenci Bilgi Sistemi veritabanında tutulmaktadır. Bu veritabanından elde edilen bir tablo, çalışma veri ambarına eklenmiştir. Bu tablo, Öğrenci Bilgi Sistemi tablosu (t_ÖBS) olarak isimlendirilmiştir (Görsel 3.3). t_ÖBS’de 2019-2020 öğretim yılı Güz dönemi için öğrenenlerin aldıkları dersler, notları, bölümleri, kayıt türleri, sistem kullanım özet bilgileri, cinsiyet, yaş, yaşadıkları şehir, ülke ve meslek gibi demografik verileri bir araya getirilmiştir. Bu tablo 57 alan, 5.762.985 toplam ve 1.046.142 tekil kayıttan oluşmaktadır.



Görsel 3.3. Öğrenci Bilgi Sistemi veritabanı yapısı

3.3.1.2. Öğrenme Yönetim Sistemi veritabanı

Öğrenme Yönetim Sistemi (ÖYS) veritabanı, öğrenenlerin ÖYS üzerindeki tüm hareketlerine yönelik verilerin tutulduğu veritabanıdır. ÖYS veritabanı oturum, ders ve içerik etkinlik verilerinden oluşmaktadır. Burada öğrenenlerin sisteme ve derslere giriş ve çıkış zamanları, sistemde kalma süreleri, sisteme giriş sayıları, öğrenme malzemeleri erişimlerine ilişkin veriler, deneme sınavları ve forum kullanımlarına ilişkin veriler yer almaktadır (Görsel 3.4). Bu veritabanında öğrenenlerin ÖYS'deki dijital ayak izleri yer almaktadır.



Görsel 3.4. Öğrenme Yönetim Sistemi veritabanı yapısı

ÖYS veritabanında veri modelleme görevlerinde kullanılmak üzere temel tablo olan “Tüm Faaliyet” tablosu (t_TF) oluşturulmuştur. Bunun için öğrenenlerin 2019-2020 öğretim yılı Güz döneminde yaptıkları oturum açma, derse tıklama, öğrenme malzemeleri erişimi, forum kullanımı, çözdükleri deneme sınavları ve puanları gibi ÖYS üzerindeki tüm hareketleri birleştirilmiştir. Tüm Faaliyet tablosunun elde edilmesi için 5 kaynak ve 3 yardımcı tablo kullanılmıştır:

- **Oturum Verileri Tablosu:** Bu tabloda oturumlara ilişkin veriler yer almaktadır. Tablo, 10 alan ve 84.326.766 kayıttan oluşmaktadır.
- **Deneme Sınavları Tablosu:** Bu tabloda deneme sınavı kullanımına ilişkin veriler yer almaktadır. Tablo, 17 alan ve 32.681.732 kayıttan oluşmaktadır.
 - **Dönüştürülmüş Ünite Verisi Tablosu:** Bu tablo, Deneme Sınavları tablosundan elde edilmiştir. Bu tablo, ünite değerlerinin yeni değerlere dönüştürüldüğü tablodur. Tablo, 3 alan ve 58 kayıttan oluşmaktadır.
- **Öğrenme Malzemeleri Erişim Tablosu:** Bu tabloda öğrenenlerin içerik kullarımlarına ilişkin veriler yer almaktadır. Tablo, 10 alan ve 352.938.808 kayıttan oluşmaktadır.
 - **Dönüştürülmüş Malzeme Türü Tablosu:** Bu tablo, Öğrenme Malzemeleri Kullanım tablosundan elde edilmiştir. Bu tabloda, içerik türleri yeni değerlere dönüştürülmüştür. Tablo, 2 alan ve 161 kayıttan oluşmaktadır.
 - **Dönüştürülmüş Malzeme Kodu Tablosu:** Bu tablo, Dönüştürülmüş Malzeme Türü tablosundan elde edilmiştir. Bu tabloda, malzeme türleri harf değerleri ile kodlanmıştır. Tablo, 3 alan ve 36 kayıttan oluşmaktadır.
- **Forum Kullanım Verileri Tablosu:** Bu tabloda forumlardaki hareketlere ilişkin veriler yer almaktadır. Tablo, 10 alan ve 287.765 kayıttan oluşmaktadır.
- **Ders Erişim Verileri Tablosu:** Bu tabloda öğrenenlerin ders erişimlerine yönelik veriler yer almaktadır. Tablo, 10 alan ve 352.938.808 kayıttan oluşmaktadır.

Bu tablolardaki veriler üzerinde veri birleştirme işlemi yapılmış ve Tüm Faaliyet tablosu oluşturulmuştur. Bunun yanı sıra diğer tablolardan elde edilen verilere ek olarak oturum id (sid), sıra, süre (sn) ve tekrarsız faaliyet alanları oluşturulmuştur. Bu alanların elde

edilmesi için Tüm Faaliyet tablosu Öğrenci No ve oturum zamanına göre sıralanmıştır. Böylece sid ve işlem sıraları belirlenmiştir. Bir faaliyette geçen sürenin belirlenmesi için öğrenenlerin ilgili faaliyetleri ile bir sonraki faaliyetleri arasındaki süre hesaplanmıştır. Oturumdaki son faaliyetin süresi ise son işlem süresi hesaplanmadığı için -1 ile işaretlenmiştir. Çoklu tıklamalarının önüne geçilmesi amacıyla bir oturumda bir dersin aynı ünitesine ait aynı malzemeye arka arkaya tıklamaların tekil sayılabilmesi amacıyla Tekrarsız faaliyet sütunu oluşturulmuş ve tekrar durumları etiketlenmiştir. Tüm Faaliyet tablosu, 21 alan ve 182.405.323 kayıttan oluşmaktadır (Görsel 3.5).



Görsel 3.5. Tüm Faaliyet tablosunda yer alan alanlar

t_TF tablosu kullanılarak 2 farklı tablo ve bu tablolardaki istatistiklere dayalı 2 özet tablo elde edilmiştir:

- **Oturum Bazlı Faaliyet Tablosu (t_OF):** Bu tablo, oturumlara göre malzeme kullanım örüntülerinin belirlenmesi amacıyla hazırlanmıştır. Bu tabloda, dersler gözetilmeden bir oturumda gerçekleştirilen faaliyetler ve frekansları özetlenmiştir. Tabloda, 24 alan ve 6.601.044 kayıt bulunmaktadır. Bu tablo; Öğrenci No, sid, İşlemler, İşlemler_Özet, İşlemler_Özet_Tekrar Sayısı, Oturum Zamanı, Örüntü, Öğrenme Malzemeleri erişim durumu ve tarih kontrol alanlarından oluşmaktadır.
 - **Oturum Bazlı Faaliyet Özet Tablosu (t_OFö):** Oturumlara ilişkin hazırlanmış özet tablodur. Tabloda, 22 alan ve 607.706 kayıt bulunmaktadır. Bu tablo; Öğrenci No, İlk Oturum Tarihi, Oturum Sayısı, İlk Oturum Haftası, Oturum Açılan Gün Sayısı, Günlük Ortalama Oturum Açma Sayısı, Toplam Faaliyet Sayısı, Toplam Faaliyet Süresi (sn) ve öğrenme malzemeleri erişim durumu alanlarından oluşmaktadır. Bu tablodan öğrenenlerin ara sınav ve dönem sonu sınavına kadar olan erişim durumları hesaplanarak *Oturum Bazlı Faaliyet Özet Tablosu_DönemSonu* (t_OFö_DS) ve *Oturum Bazlı Faaliyet Özet Tablosu_Arasınav* (t_OFö_AS) olmak üzere 2 farklı tablo elde edilmiştir. t_OFö_DS, 22 alan ve 602.372 kayıttan oluşmaktadır. t_OFö_AS ise 22 alan ve 568.065 kayıttan oluşmaktadır.
- **Oturum ve Ders Bazlı Faaliyet Tablosu (t_ODF):** Oturum Bazlı Faaliyet tablosunun ders bazlı düzenlenmiş halidir. Tabloda, 25 alan ve 10.631.523 kayıt bulunmaktadır.
 - **Oturum ve Ders Bazlı Faaliyet Özet Tablosu (t_ODFö):** Oturum Bazlı Faaliyet Özet tablosunun ders bazlı olarak düzenlenmiş halidir. Tabloda, 23 alan ve 2.499.132 kayıt bulunmaktadır. Bu tablodan ara sınav ve dönem sonu sınavına kadar olan erişim durumları hesaplanarak *Oturum ve Ders Bazlı Faaliyet Özet Tablosu_DönemSonu* (t_ODFö_DS) ve *Oturum ve Ders Bazlı Faaliyet Özet Tablosu_Arasınav* (t_ODFö_AS) olmak üzere 2

farklı tablo elde edilmiştir. t_ODFö_DS, 23 alan ve 2.482.424 kayıttan oluşmaktadır. t_ODFö_AS ise 23 alan ve 2.280.002 kayıttan oluşmaktadır.

3.4. Araştırma Süreci

Bu araştırma tanımlayıcı, tahmin edici ve normatif analitik olmak üzere 3 aşamadan oluşmaktadır. Bu bölümde, her bir aşamada gerçekleştirilen işlem ve uygulamalar açıklanmıştır. Bu çalışma kapsamında veri hazırlama ve düzenleme işlemleri MSSQL Server ve Tableau Prep Builder, veri modelleme işlemleri RapidMiner Studio ve IBM SPSS Modeler, veri görselleştirme işlemleri ise Tableau programları kullanılarak gerçekleştirilmiştir.

3.4.1. Tanımlayıcı analitik aşaması

Tanımlayıcı analitikte, veriler analiz edilerek var olan durum ortaya konulur ve tanımlanır (IBM, 2017). Tanımlayıcı modellerde veri setindeki verilerin özellikleri karakterize edilir ve örüntüler ortaya çıkarılır (Han vd., 2012). Bu analitik türü ile “*Ne oldu, problem nedir, ne sıklıkla ve nerede yaşanmaktadır?*” gibi sorulara yanıt aranmaktadır. Yapılan tanımlayıcı analizler sonucunda uyarılar, raporlar ve gösterge tabloları oluşturulabilir (IBM, 2017).

Tanımlayıcı analitik aşamasında, Araştırma Sorusu 1 ve 2 kapsamında Anadolu eKampüs Sistemini kullanan öğrenenlerin sistem kullanım davranışlarındaki örüntülerin belirlenmesi; benzer özelliklerine göre bir araya getirilerek öğrenen özelliklerinin derinlemesine incelenmesi ve öğrenen gruplarının belirlenmesi amaçlanmaktadır. Araştırmanın ilk aşamasının çalışma kümesini, 2019-2020 öğretim yılı Güz döneminde Anadolu Üniversitesi Açıköğretim Sistemine kayıtlı olan ve Anadolu eKampüs Sistemini kullanan öğrenenlerin tamamı oluşturmaktadır. Bu aşamada veri kaynağı olarak; Anadolu eKampüs Öğrenme Yönetim Sistemi Veritabanı ve Öğrenci Bilgi Sistemi Veritabanından elde edilen veriler kullanılmıştır.

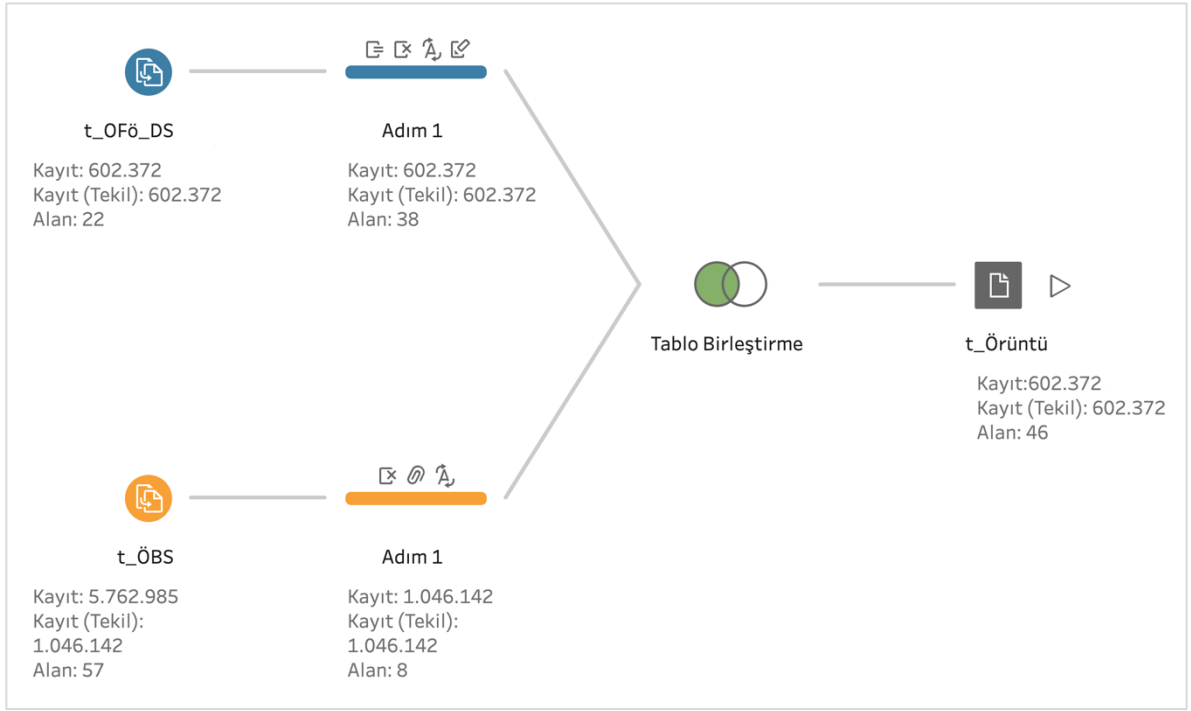
3.4.1.1. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi

Bu bölümde, öğrenme davranışlarındaki örüntülerin belirlenmesi sürecinde verilerin hazırlanması ve veri keşfi süreçleri ile algoritmaların özellikleri ele alınmıştır.

3.4.1.1.1. Verilerin hazırlanması ve veri keşfi

Bu bölümde, e-öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesine yönelik gerçekleştirilen veri temizleme, dönüştürme ve birleştirme işlemleri açıklanmıştır.

Öğrenenlerin e-öğrenme ortamında öğrenme davranışlarındaki örüntülerin belirlenmesi için t_OFö_DS ve t_ÖBS tablolarındaki veriler kullanılmıştır. Bu tablolarda yapılan veri temizleme, dönüştürme ve birleştirme işlemlerinin ardından “Örüntü Tablosu (t_Örüntü)” oluşturulmuştur. t_OFö_DS, öğrenenlerin 20 Ocak 2020’ye kadar olan tüm faaliyetlerini kapsayan özet tablodur. Tablo 22 alan, 602.372 toplam kayıt ve 602.372 tekil kayıttan oluşmaktadır. t_ÖBS ise 2019-2020 öğretim yılı Güz döneminde kayıtlı olan öğrenenlerin demografik verileri ve ders bazlı akademik performans puanlarını içermektedir. Tablo 57 alan, 5.762.985 toplam kayıt ve 1.046.142 tekil kayıttan oluşmaktadır. İlk adımda her iki tabloda da veri temizleme, dönüştürme, hesaplanmış alan üretme ve filtreleme işlemleri yapılmıştır. Bunun ardından tablolar, öğrenci numaraları baz alınarak birleştirilmiştir. Yapılan bu işlemlerden sonra, t_Örüntü tablosu elde edilmiştir (Görsel 3.6). t_Örüntü 46 alan, 602.372 toplam kayıt ve 602.372 tekil kayıttan oluşmaktadır.



Görsel 3.6. Örüntülerin belirlenmesi veri hazırlama süreci

3.4.1.1.2. Verilerin modellenmesi

Bu bölümde, öznitelik seçimi ve modellemede kullanılan algoritmaların özellikleri değerlendirilmektedir.

Öznitelik seçimi

Öğrenenlerin öğrenme davranışlarındaki örüntülerin belirlenmesi için birliktelik kuralları algoritmaları kullanılmış ve sonuçlar değerlendirilmiştir. Bu modellemelerin geliştirilmesinde IBM SPSS Modeler ve RapidMiner Studio kullanılmıştır. Analizler Apriori, CARMA ve FP-Growth algoritmaları kullanılarak gerçekleştirilmiştir. Örüntülerin belirlenmesi veri setinde, 46 alan ve 602.372 kayıt bulunmaktadır. Örüntülerin belirlenmesi için öğrenenlerin malzeme kullanım verileri analiz edilmiştir. Malzeme kullanım değerleri; öğrenenler malzemelere en az 1 kere erişmişlerse “Doğru”, hiç erişmemişlerse “Yanlış” olarak dönüştürülmüştür. Birliktelik kuralları, ikili (binary) veri türündeki öznitelikler ile gerçekleştirilmiştir. Analizlerde Tablo 3.1’deki öznitelikler kullanılmıştır.

Tablo 3.1. Örüntülerin belirlenmesinde kullanılan öznelilikler

Alan	Tür	Değerler	
		Doğru	Yanlış
Canlı Ders Kayıtları Erişimi	Binominal	145.323	457.049
Çıkmış Sınav Soruları Erişimi	Binominal	475.076	127.290
Deneme Sınavı Erişimi	Binominal	195.128	407.244
Ders Kitabı Erişimi	Binominal	320.522	281.850
eDers Erişimi	Binominal	59.013	543.359
İnfografik Erişimi	Binominal	27.166	575.206
Ses Tabanlı Malzemelere Erişim	Binominal	212.952	389.420
Ünite Metni Erişimi	Binominal	310.465	291.905
Ünite Özeti Erişimi	Binominal	371.786	230.586
Video Erişimi	Binominal	238.257	364.115

Örüntü Keşfi

Örüntü, bir veri setinde sıklıkla birlikte görüntülenen nesne kümeleri, örüntü keşfi ise büyük veri kümelerinden sık örüntülerin ve güçlü ilişkilerin ortaya çıkarılması olarak tanımlanabilir (Han vd., 2012). Örüntü keşfinde kullanılan yöntemlerden biri, birliktelik kurallarıdır (Agrawal vd., 1993). Birliktelik kurallarında iki aşamalı bir süreç yürütülmektedir (Han vd., 2012):

1. Veri setindeki sık görülen nesne kümelerinin tamamı belirlenir.
2. Sık görülen nesne kümelerden güçlü birliktelik kuralları oluşturulur.

Bu iki aşamalı sürecin tamamlanmasının ardından kurallar elde edilmektedir. Birliktelik kuralları, öncüller ve sonuçlardan oluşmaktadır. Ancak burada öğeler arasında bir nedensellik değil ilişki bulunmaktadır. Birliktelik kuralı örneği aşağıda verilmiştir:

$$\text{Lego} \Rightarrow \text{Süt saklama kabı} [\text{Destek} = \%75, \text{Güven} = \%90]$$

Bu örnekte Lego öncül, süt saklama kabı ise sonuçtur. Kural desteği (support) ve güven (confidence) değerleri kural ilginçliğinin ölçüleridir (Zhao ve Bhowmick, 2003). Destek değeri keşfedilen kuralın yararlılığını, güven değeri ise kesinliğini yansıtmaktadır (Han vd.,

2012). Elde edilen kurala göre tüm işlemlerin %75'inde Lego ve süt saklama kabı birlikte satın alınmıştır. Aynı zamanda Lego alan müşterilerin %90'ı süt saklama kabı da almıştır. Destek değeri, tüm işlemlerde Lego ve süt saklama kabının birlikte görülme olasılığıdır. Güven değeri ise, Lego içeren bir işlemin süt saklama kabını da içermesi olasılığıdır. Destek ve güven değerleri aşağıdaki formüllerle hesaplanmaktadır:

$$\text{Destek } (X \Rightarrow Y) = \frac{\text{Tüm işlemlerde } X \text{ ve } Y' \text{nin birlikte görülme sayısı}}{\text{Toplam işlem sayısı}}$$

$$\text{Güven } (X \Rightarrow Y) = \frac{\text{Tüm işlemlerde } X \text{ ve } Y' \text{nin birlikte görülme sayısı}}{X' \text{in görüldüğü toplam işlem sayısı}}$$

Destek ve güven değerleri kural ilginçliğinin belirlenmesinde her zaman yeterli olmayabilir. Bu nedenle bu değerlere ek olarak kural ilginçliğinin belirlenmesinde lift (kaldıraç) değeri de kullanılmaktadır. Lift değeri aşağıdaki formülle hesaplanmaktadır:

$$\text{Lift } (X \Rightarrow Y) = \frac{\text{Destek } (X \Rightarrow Y)}{P(X) * P(Y)}$$

Lift değerinin 1'den büyük olması, öncüller ve sonuçların beklenenden daha sık birlikte görüldüğünü göstermektedir (IBM, 2014). Bu durum, öncüller ve sonuçların pozitif korelasyona sahip olduğunu yani birinin ortaya çıkmasının diğerinin ortaya çıkmasını olumlu yönde etkilediğini göstermektedir (Han vd., 2012). Değer, 1'e eşitse öncül ve sonuçların birbirinden bağımsız olduğu ve aralarında bir ilişki olmadığı, 1'den küçükse öncül ve sonuçların negatif ilişkili olduğu değerlendirilmektedir (Han vd., 2012).

Bu çalışmada öğrenme davranışlarındaki örüntülerin ortaya çıkarılması amacıyla Apriori, CARMA ve FP-Growth algoritmaları kullanılmıştır:

- **Apriori Algoritması:** Apriori algoritması, Agrawal ve Srikant tarafından geliştirilmiştir (Agrawal ve Srikant, 1994). Apriori algoritması, "Bir nesne kümesi veri setinde yaygınsa onun tüm alt kümeleri de yaygın olmalıdır." ilkesine dayanmaktadır (Tan vd., 2005). Bu algoritmada, birleştirme ve budama eylemlerinden oluşan iki aşamalı bir süreç izlenmektedir (Agrawal ve Srikant,

1994). Apriori, aday nesne kümelerin üstel büyümesini sistematik olarak kontrol etmek için desteğe dayalı budama yöntemini kullanmaktadır (Tan vd., 2019). Apriori algoritmasında, düzey bazında arama olarak bilinen yinelemeli bir yaklaşım kullanılmaktadır (Han vd., 2012). Apriori algoritmasında öncelikle minimum desteği karşılayan sık görülen aday nesne kümeleri tekrarlı bir süreçle oluşturulmaktadır. Bunlardan seyrek olanlar budanmaktadır. Yeni bir sık görülen nesne kümesi elde edilemeyince veri setindeki tarama işlemleri sonlandırılır ve birliktelik kuralları üretilir. Bu çalışmada, Apriori algoritması IBM SPSS Modeler'da çalıştırılmıştır. Apriori düğümü, verilerden bir dizi kural çıkararak en yüksek bilgi içeriğine sahip kuralları sunmaktadır (IBM, 2011). Apriori, büyük veri kümelerini verimli bir şekilde işlemek için karmaşık bir indeksleme şeması kullanır (IBM, 2011). Apriori algoritmasında verilerin türleri ikili (binary) olarak düzenlenmelidir. Bu çalışmada minimum destek değeri %20, güven değeri ise %85 olarak girilmiş ve öğrenme malzemeleri kullanımındaki örüntüler belirlenmiştir.

- **CARMA Algoritması:** CARMA düğümü, verilerdeki birliktelik kurallarını keşfetmek için bir birliktelik kuralları keşif algoritması kullanmaktadır (IBM, 2011). Apriori'nin aksine, CARMA düğümü, yalnızca öncül desteği yerine kural desteği (hem öncül hem de sonuç için destek) için de ayarlar sunmaktadır (IBM, 2011). CARMA ayrıca birden çok sonucu olan kurallara da izin vermektedir. Bu çalışmada, CARMA algoritması IBM SPSS Modeler'da çalıştırılmıştır. Minimum destek değeri %20, güven değeri ise %85 olarak girilmiş ve öğrenme malzemeleri kullanımındaki örüntüler belirlenmiştir.
- **FP-Growth (Frequent Pattern Growth) Algoritması:** FP-Growth algoritması, işlemlerden oluşan bir veritabanında sıklıkla birlikte meydana gelen nesnelere hesaplamak için verimli bir algoritmadır (RapidMiner, 2021a). Bu algorithmada, Apriori algoritmasının aday oluştur-test et paradigmasından farklı olarak FP-Tree yapısı ile veritabanı kodlanmakta ve sık görülen nesne kümelerini elde edilmektedir (Tan vd., 2019). FP-Tree, giriş verilerinin sıkıştırılmış bir temsili olarak ifade edilebilir (RapidMiner, 2021a). FP-Growth algoritması, veritabanını 2 kez taramaktadır. İlk taramada, Apriori ile aynı şekilde sık görülen nesne kümeleri ve

bunların destek sayıları üretilmektedir (Han vd., 2012). Daha sonra FP-Tree veri yapısı oluşturulmakta ve veritabanı ikinci kez taranmaktadır. Son adımda, FP-Tree yapısı kullanılarak birliktelik kuralları üretilmektedir. Bu çalışmada, FP-Growth algoritması RapidMiner’da çalıştırılmıştır. Minimum destek değeri %95, güven değeri ise %85 olarak girilmiş ve öğrenme malzemeleri kullanımındaki örüntüler belirlenmiştir.

3.4.1.1.3. Modellerin değerlendirilmesi

Öğrenenlerin ÖYS’deki öğrenme malzemeleri kullanım davranışlarındaki örüntülerin belirlenmesi için Apriori, CARMA ve FP-Growth algoritmaları kullanılmıştır. Elde edilen modellerin değerlendirilmesinde destek, güven ve lift değerleri kullanılmıştır.

3.4.1.2. Çevrimiçi öğrenme ortamında öğrenen profillerinin belirlenmesi

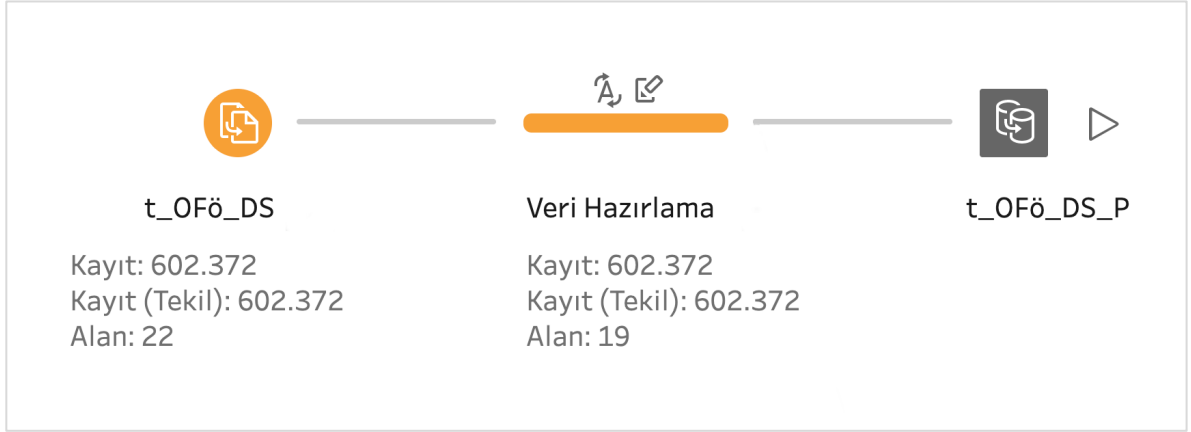
Öğrenen profillerinin belirlenmesi süreci, verilerin hazırlanması ve veri keşfi ile veri modellemesi adımlarından oluşmaktadır. Bu bölümde, bu adımlarda yapılan işlemler açıklanmaktadır.

3.4.1.2.1. Verilerin hazırlanması ve veri keşfi

Verilerin hazırlanması ve veri keşfi süreci, kümeleme analizinin gerçekleştirileceği veri setinin oluşturulması ve veri ön işleme aşamalarından oluşmaktadır.

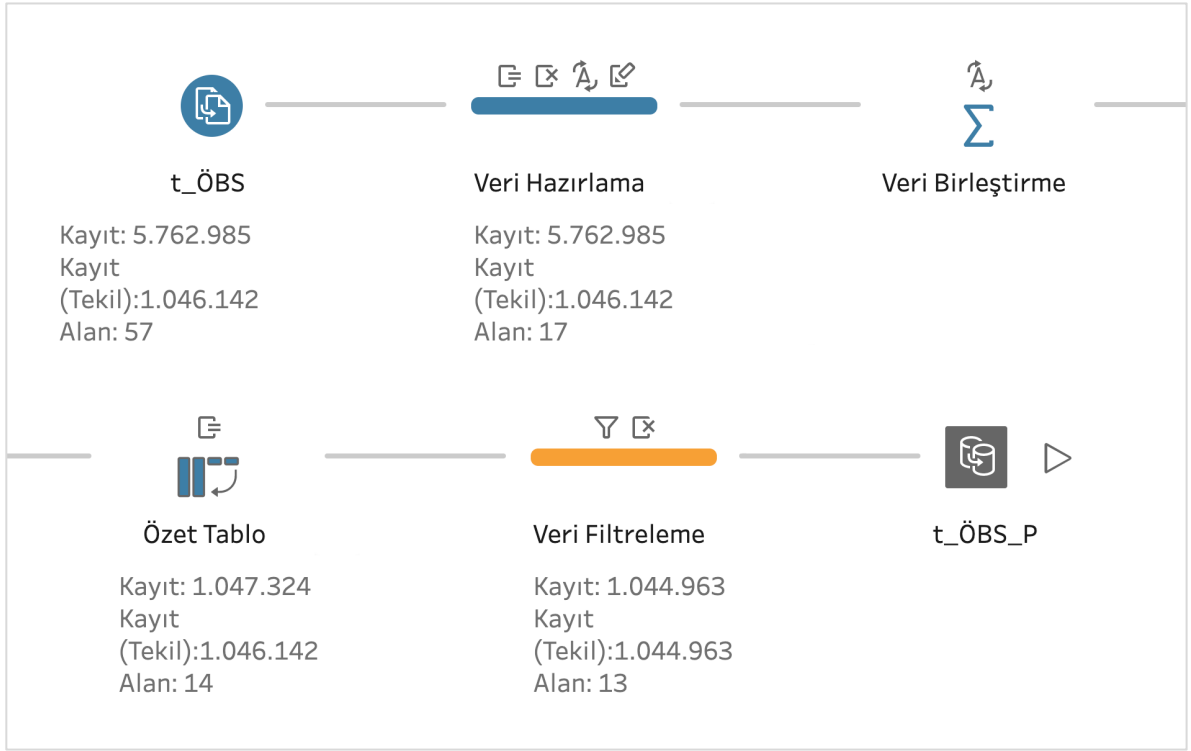
Veri setinin oluşturulması

Öğrenen profillerinin belirlenmesi için t_OFö_DS ve t_ÖBS tablolarındaki veriler kullanılmıştır. Bu tablolarda yapılan veri temizleme, dönüştürme ve birleştirme işlemlerinin ardından “Profil Modeli Tablosu (t_Profil)” oluşturulmuştur. İlk düzenlemeler, t_OFö_DS’de yapılmıştır. t_OFö_DS, öğrenenlerin 20 Ocak 2020’ye kadar olan tüm faaliyetlerini içeren özet tablodur. Tablo 22 alan, 602.372 toplam kayıt ve 602.372 tekil kayıttan oluşmaktadır. Bu tablo üzerinde veri hazırlama adımında veriler dönüştürülmüş ve analize uygun hale getirilmiştir (Görsel 3.7).



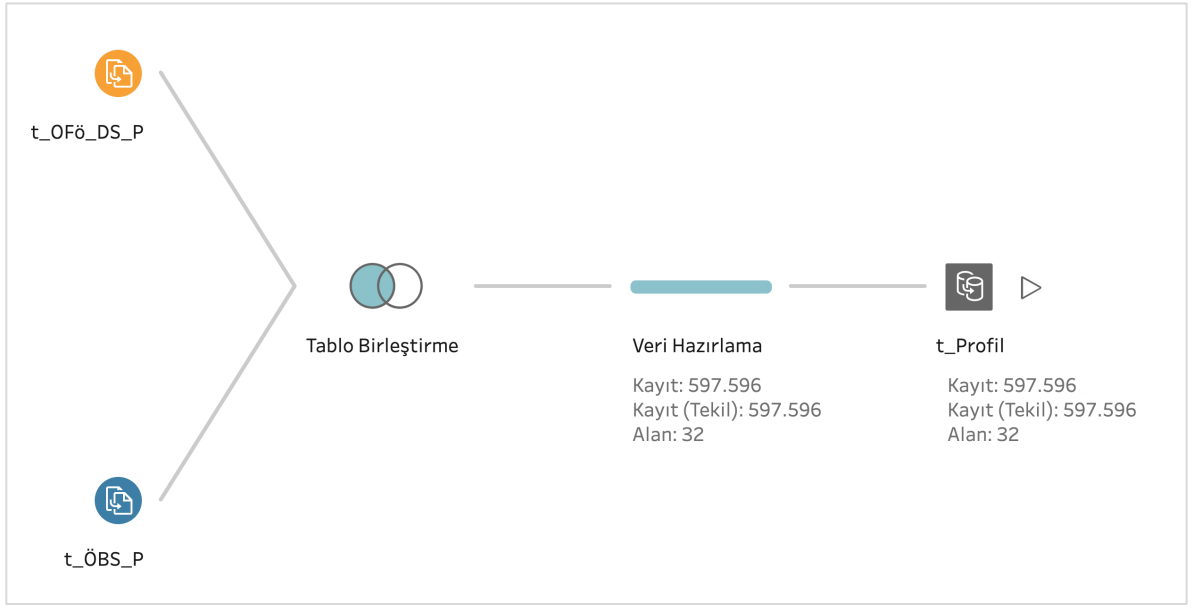
Görsel 3.7. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-I

t_OFö_DS tablosundaki düzenlemeler tamamlanınca t_ÖBS üzerinde düzenlemeler yapılmıştır. t_ÖBS, 2019-2020 öğretim yılı Güz döneminde kayıtlı olan öğrenenlerin demografik verileri ve ders bazlı akademik performans puanlarını içermektedir. Tablo 57 alan, 5.762.985 toplam kayıt ve 1.046.142 tekil kayıttan oluşmaktadır. t_ÖBS tablosunda veri hazırlama, veri birleştirme ve veri filtreleme aşamaları uygulanmıştır. Veri hazırlama aşamasında sınav notlarındaki 555, 666 ve 888 değerleri 0 (sıfır) değerine dönüştürülmüştür. Öğrenenlerin sınava girme durumlarının yüzdesel olarak elde edildiği hesaplanmış iki alan oluşturulmuştur. Bu işlemin ardından veriler, Öğrenci numaralarına göre gruplandırılmıştır. Yapılan işlemin ardından öğrenenlerin bazılarının farklı bölümlerde de kayıtları olduğundan dolayı birden fazla kayda sahip oldukları belirlenmiştir. Birden fazla kaydı olan kayıtlar filtreleme adımında veriden çıkarılmıştır (Görsel 3.8).



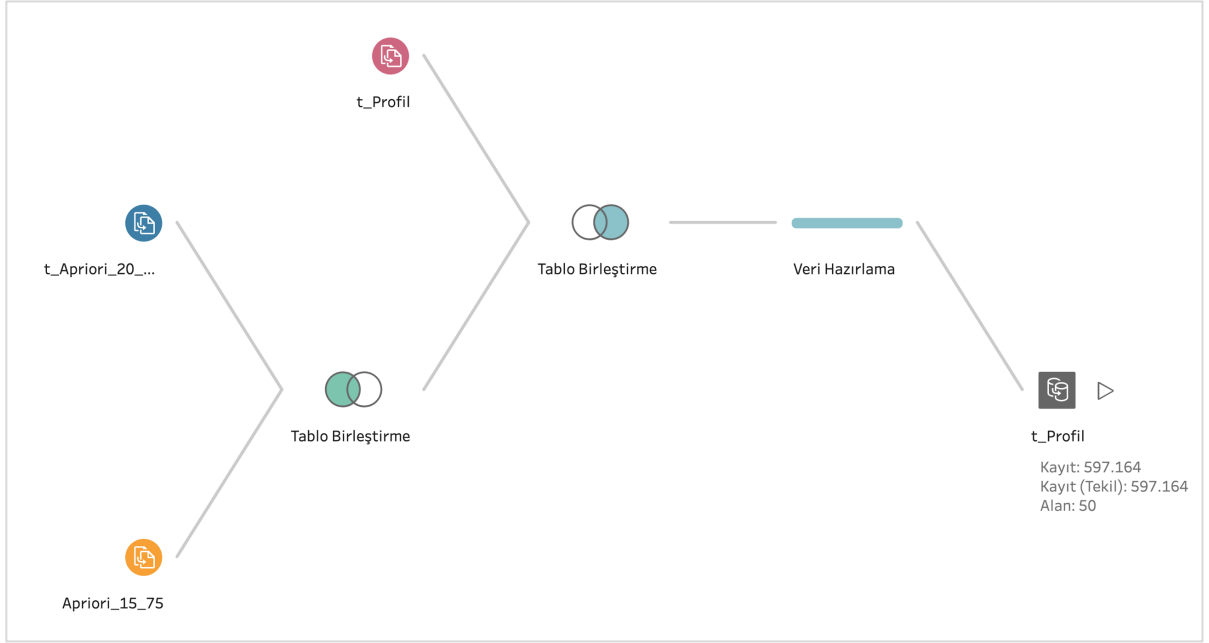
Görsel 3.8. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-II

Bu işlemlerden sonra t_OFö_DS_P ve t_ÖBS_P tabloları birleştirilmiştir. Dönemlik genel not ortalamaları hesaplanmayan öğrenenler veriden çıkarılmış ve t_Profil tablosu elde edilmiştir (Görsel 3.9). t_Profil 32 alan, 597.596 toplam kayıt ve 597.596 tekil kayıttan oluşmaktadır.



Görsel 3.9. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-III

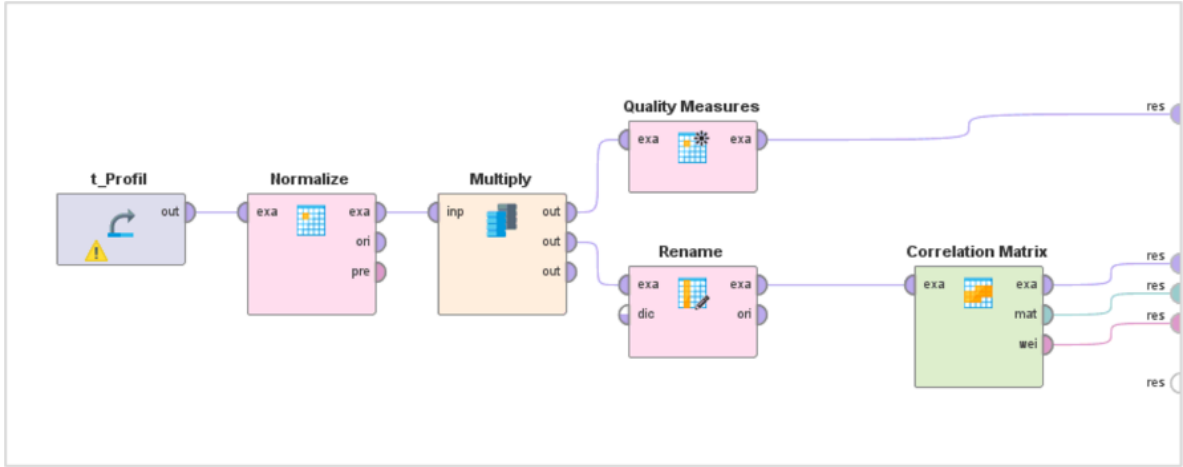
Profillerin belirlenmesi aşamasından önce birliktelik kuralları aracılığıyla örüntüler belirlenmiştir. Apriori algoritması ile elde edilen iki farklı analiz sonucu bu tabloya eklenmiştir. İlk birliktelik kuralları minimum destek değeri %20 ve güven değeri %85, ikinci birliktelik kuralları ise minimum destek değeri %15 ve güven değeri %75 değerlerine göre elde edilmiştir. Bu kurallar, `t_Profil` tablosuna eklenmiştir. Son olarak yurt dışı programlarına kayıtlı olan öğrenenler veriden çıkarılmış ve profillerin belirlenmesi çalışmasının gerçekleştirileceği tablo üzerindeki işlemler tamamlanmıştır (Görsel 3.10). `t_Profil`; 50 alan, 597.164 toplam ve 597.164 tekil kayıttan oluşmaktadır.



Görsel 3.10. Öğrenen profillerinin belirlenmesi veri hazırlama süreci-IV

Veri ön işleme süreci

t_Profil veri setinde sayısal değerler üzerinde min-maks normalizasyonu gerçekleştirilmiştir. Bu çalışmadaki öznitelik değerleri normal dağılım göstermediği ve min-maks normalizasyonu verilerin orijinal dağılımını koruduğu için bu normalleştirme türü tercih edilmiştir (RapidMiner, 2021k). Minimum değer 0, maksimum değer ise 1 olarak girilmiştir. Böylece tüm öznitelik değerleri 0-1 aralığında yer alacak şekilde normalleştirilmiştir. Normalleştirme işleminin ardından özniteliklerin kalite ölçümleri yapılmıştır. Bu işlemde kararlılık (stability) değerleri 0,90'dan yüksek çıkan eDers ve İnfografik öznitelikleri veri setinden çıkarılmıştır. Kararlılık değerinin yüksek olması o alandaki değerlerin neredeyse aynı olduğunu göstermektedir. Veri ön işleme sürecine öznitelikler arasındaki ilişkileri gösteren korelasyon matrisi ve öznitelik ağırlıkları hesaplanarak devam edilmiştir. Bu süreç, Görsel 3.11'de sunulmaktadır.




Görsel 3.11. *Veri temizleme ve veri keşfi süreci*

Profillerin belirlenmesine yönelik hazırlanan t_Profil veri setindeki özniteliklerden en yüksek ağırlığa sahip 10 öznitelik aşağıda sıralanmıştır:

1. Yaş
2. Toplam Faaliyet Süresi (dk)
3. Günlük Ortalama Oturum Açma Sayısı
4. Ses Tabanlı Malzeme Erişim Sayısı
5. Ders Kitabı Erişim Sayısı
6. Canlı Ders Kayıtları Erişim Sayısı
7. Ünite Metni Erişim Sayısı
8. Video Erişim Sayısı
9. Deneme Sınavı Erişim Sayısı
10. Ünite Özeti Erişim Sayısı

Analiz sonucunda en düşük ağırlığa sahip olan özniteliğin “Oturum Sayısı” olduğu belirlenmiştir. Bu nedenle, bu özniteliğin kümeleme analizinde yer almaması küme kalitesine olumlu etki yapabilir. Burada öznitelik ağırlıkları normalleştirilmiştir. Korelasyon analizi sonucu elde edilen korelasyon matrisinin görselleştirilmiş versiyonu ise Şekil 3.5’te verilmiştir.



Şekil 3.5. Görselleştirilmiş korelasyon matrisi

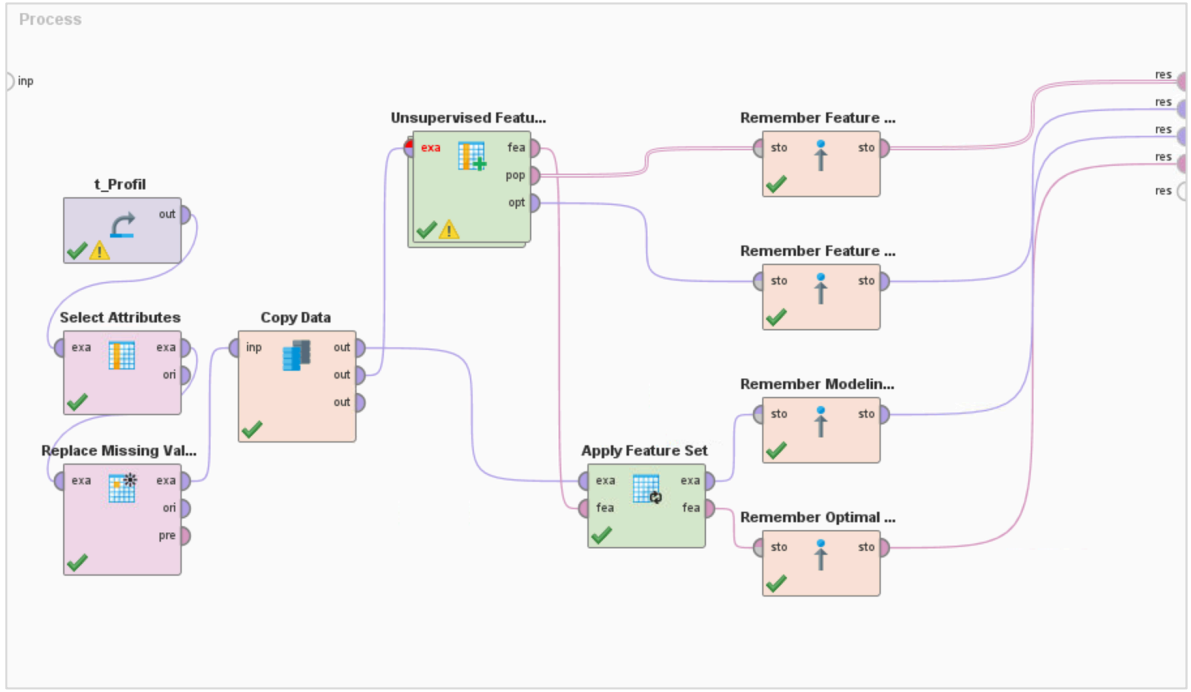
Şekil 3.5 incelendiğinde özniteliklerin arasında pozitif korelasyon olduğu görülmektedir. En güçlü ilişkiler ise “Dönem Sonu Sınav Puanı” ile “Dönem Sonu Ortalama Puan” ve “Oturum Sayısı” ile “Oturum Açılan Gün Sayısı” öznitelikleri arasında gözlemlenmiştir. Bu öznitelikler birbirine benzemekle birlikte birbirinden farklı durumları ifade etmektedir. Bu nedenle, analiz sırasında deneysel olarak çıkarılmalarının eğitsel çıktılar açısından daha uygun olacağı düşünülmüştür.

3.4.1.2.2. Verilerin modellenmesi

Bu bölümde, öznitelik mühendisliği (feature engineering) ve modellemede kullanılan algoritmaların özellikleri değerlendirilmektedir.

Öznitelik mühendisliği süreci

Öznitelik mühendisliği sürecinde kümeleme analizinde kullanılacak özniteliklerin belirlenmesi için RapidMiner Studio’da yer alan gözetimsiz öğrenme için öznitelik seçimi (unsupervised feature selection) operatörü kullanılmıştır. Operatör, en iyi öznitelik kümelerini bulmak için çok amaçlı bir evrimsel algoritma kullanmaktadır (RapidMiner, 2021b). Küme modeli performansı, bu operatör tarafından otomatik olarak hesaplanan Davies Bouldin indeksi ile ölçülmektedir. Küme ayrımlarının daha iyi yapılabilmesi için Davies Bouldin indeksi değerinin düşük olması beklenmektedir. Öznitelik seçim sürecinde yapılan işlemler, Görsel 3.12’de özetlenmiştir.



Görsel 3.12. Öznitelik seçim süreci

Öznitelik seçimi analizinin sonuçları, Şekil 3.6’da verilmiştir.



Şekil 3.6. Öznitelik seçimi sonuçları

Şekil 3.6’daki her nokta, farklı öznitelik kümelerini temsil etmektedir. Küme modeli performansı, Davies Bouldin indeksi ile ölçüldüğünden dolayı küme kalitesinin düşük

değerlerde olması tercih edilmektedir. Kümeleme analizinde öznitelik sayısı azaldığında kümeleme başarısının artacağı söylenebilir. Ancak bu durum veri kaybına ve orijinal veriden uzaklaşmaya neden olabilir. Bu nedenle Şekil 3.6’da verilen farklı öznitelik setlerinden karmaşıklık ve küme kalitesi optimum olan öznitelik seti seçilmiştir. Bu öznitelik seti, 14 öznitelikten oluşmaktadır ve orijinal veri setine göre daha yüksek küme kalitesine sahiptir.

Özellik seçimi ile elde edilen öznitelikler;

- Toplam Faaliyet Süresi (dk),
- Ara Sınav Puanı,
- Sınava Girme Oranı,
- Oturum Sayısı,
- Ders Kitabı Erişim Sayısı,
- Ünite Metni Erişim Sayısı,
- Kullanılan Malzeme Türü Sayısı,
- Dönem Sonu Sınav Puanı,
- Oturum Açılan Gün Sayısı,
- Günlük Ortalama Oturum Açma Sayısı,
- Toplam Faaliyet Sayısı,
- Canlı Ders Kayıtları Erişim Sayısı,
- Dönem Sonu Ortalama Puan ve
- Yaş olarak belirlenmiştir.

Kümeleme Analizi

Öğrenen profillerinin belirlenmesinde kümeleme analizi kullanılmıştır. Profil belirleme ve segmentasyon problemlerinin çözümünde sıklıkla kullanılan yöntemlerden biri, kümeleme analizidir (Wendler ve Gröttrup, 2021). Kümeleme analizi kullanılarak e-öğrenme ortamındaki öğrenen davranışları hakkında bilgi sahibi olunabilir. Veri setinde doğal olarak var olan grupların ortaya çıkarıldığı kümeleme analizi, gözetimsiz bir makine öğrenmesi olup kullanılan veriler etiketsizdir (Dunham, 2003). Kümeleme analizinde küme içindeki benzerliğin maksimum, kümeler arasındaki benzerliğin ise minimum yapılması amaçlanmaktadır (Han vd., 2012). Kümeleme algoritmaları bölümlenmeli, hiyerarşik,

yoğunluk tabanlı ve ızgara (grid) tabanlı algoritmalar olarak sınıflandırılabilir (Han vd., 2012).

Bu çalışmada öğrenen profillerinin belirlenmesi amacıyla TwoStep ve k-Means algoritmaları kullanılmıştır:

- **TwoStep Algoritması:** TwoStep algoritması, hiyerarşik bir kümeleme algoritmasıdır (Wendler ve Gröttrup, 2021). Bu algoritma, birleştirici hiyerarşik bir yonteme dayanır ve kümelerin oluşturulmasında tümevarım yöntemi kullanılır (Reddy ve Vinzamuri, 2014). Bu yöntemde başlangıçta her veri nesnesi ayrı kümeler olarak ele alınır. Ardından her adımda benzerliklerine göre veri nesnelere birleştirilir ve bu işlem tamamlandığında kümeler elde edilmektedir. TwoStep algoritması farklı veri türleri ve büyük veri kümeleri ile çalışabilmekte, küme sayısını otomatik olarak hesaplayabilmekte ve aykırı değerleri belirleyerek otomatik olarak dışlayabilmektedir (IBM, 2011). TwoStep algoritması, bir ağaç yapısı (CF-Tree) kullanarak veri kümelerini işlemektedir (Wendler ve Gröttrup, 2021). Algoritma, ön kümeleme ve kümeleme olmak üzere iki aşamadan oluşmaktadır. İlk aşamada her kayıt alt kümelere ayrılmakta ve ikinci aşamada ise bu kayıtlar belirlenen sayıda kümede birleştirilmektedir (IBM, 2011). Çalışma kapsamında TwoStep algoritması, IBM SPSS Modeler'da çalıştırılmıştır. Burada en uygun küme sayısı otomatik olarak hesaplanmaktadır. Uzaklık ölçüsü olarak olasılık temelli Log-likelihood ve Öklid uzaklığı seçenekleri sunulmaktadır. Çalışma veri setinde kategorik ve sayısal veriler olduğu için analizlerde Log-likelihood uzaklığı tercih edilmiştir. Öklid uzaklığı sadece sayısal öznitelikler olduğunda kullanılmaktadır. Kümeleme kriteri olarak BIC (Schwarz's Bayesian Criterion) tercih edilmiştir. Bu kriter ile optimal küme sayısı belirlenmektedir.
- **k-Means Algoritması:** Bu algoritma, bölümlenmeli bir kümeleme algoritmasıdır (Han vd., 2012). k-Means algoritmasında küme sayısı kullanıcı tarafından belirlenmektedir (MacQueen, 1967). Algoritmanın ilk adımında, belirlenen k değerine göre ilk küme merkezleri oluşturulmaktadır. İkinci adımda her nesne seçilen uzaklık ölçüsüne göre en yakın merkeze atanmaktadır. Kümeler oluşturulduktan sonra her küme için merkez noktaları yeniden hesaplanır. Küme

merkezleri kararlı hale gelene kadar ikinci ve üçüncü adımdaki işlemler yinelemeli olarak devam etmektedir. Yinelemenin kaliteyi deęiřtirmedięi, nesnelere başka bir kümeye atanamadıęı ařamada süreç sona ermektedir (Han vd., 2012; Reddy ve Vinzamuri, 2014; Wendler ve Gröttrup, 2021). Bu alıřmada yapılan analizde otomatik kümeleme sonuçlarından ve deneysel alıřmalardan yararlanılarak küme sayısı 6 olarak girilmiřtir. Veri seti sayısal ve kategorik deęiřkenlerden oluřtuęu için ölçüm türü karma ölçüm seçilmiřtir. Karma ölçüm için uzaklık ölçümü Karma Öklid Uzaklıęı ile gerekleřtirilmektedir (RapidMiner, 2021m). Bu ölçümde sayısal deęerler için Öklid Uzaklıęı hesaplanmaktadır. Kategorik deęerlerde ise iki deęer aynıysa uzaklık deęeri 0, farklıysa 1 olarak hesaplanmaktadır.

3.4.1.2.3. Modellerin deęerlendirilmesi

Öğrenen profillerinin belirlenmesinde TwoStep ve k-Means algoritmaları kullanılmıřtır. TwoStep algoritması ile elde edilen modellerin deęerlendirilmesinde Silhouette deęeri kullanılmıřtır (Rousseeuw, 1987). Bu deęer, küme ii uyumun ve kümeler arasındaki ayrımın bir ölçüsüdür (Wendler ve Gröttrup, 2021). Bu deęerin 0,25'ten küçük olması kümeleme performansının zayıf, 0,25-0,50 arasında olması orta, 0,5'in üzerinde olması ise iyi olduęunu göstermektedir. (Wendler ve Gröttrup, 2021). Silhouette deęeri 0,25'in üzerindeki deęerler kümelemenin bařarılı olduęu řeklinde yorumlanabilir.

k-Means ile elde edilen modellerin deęerlendirilmesinde Davies Bouldin indeksi (DBI) kullanılmıřtır (Davies ve Bouldin, 1979). Bu ölçü hem ayrılabilirlięi hem de kompaktlıęı dikkate almaktadır (Hofmann ve Klinkenberg, 2016). Elde edilen kümelerin kompakt ve birbirinden uzak olması düşük DBI deęerini göstermektedir (Hofmann ve Klinkenberg, 2016). Dięer bir ifadeyle küme ayrımlarının daha iyi yapılabilmesi için Davies Bouldin indeksi deęerinin düşük olması beklenmektedir.

3.4.2. Tahmin edici analitik ařaması

Tahmin edici analitikte var olan veriler üzerinde analiz yapılarak tahminler geliřtirilmektedir (Han vd., 2012). Tahmin edici modellerde, öncelikle sonuçları bilinen verilerle modeller oluřturulmakta, geliřtirilen modeller sonuçları bilinmeyen durumların

tahmin edilmesinde kullanılmaktadır. “*Gelecekte ne olacak, eğilim devam ederse neler yaşanacak, neler olabilir, hangi eylemlere gerek duyuluyor?*” gibi sorulara yanıt aranan tahmin edici analitikler ile tahmin modelleri ve öngörüler oluşturulabilmektedir (IBM, 2017). Tahmin edici analitikler kurumların veriye dayalı öngörüler geliştirmelerine, problem durumları ile ilgili anlayışlarını geliştirmelerine ve karar verme süreçlerini desteklemelerine olanak sağlamaktadır. Bu aşamada Araştırma Sorusu 3 kapsamında, öğrenenlerin akademik performanslarına yönelik tahmin modeli geliştirilmesi süreci açıklanmıştır.

3.4.2.1. Akademik performans tahmin modelinin geliştirilmesi

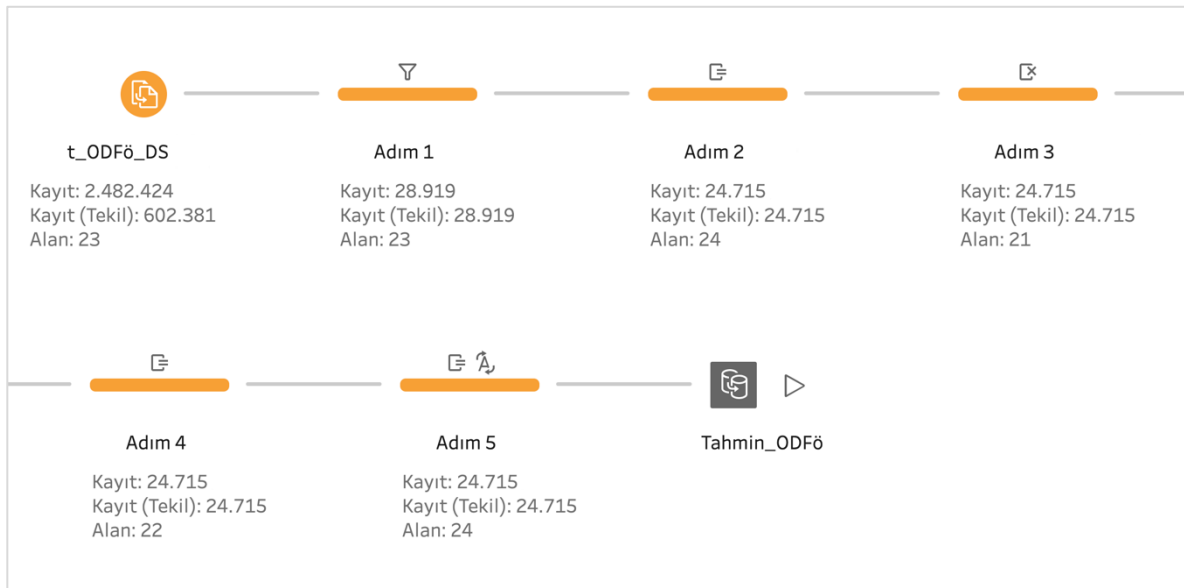
Öğrenenlerin akademik performanslarına yönelik tahmin modelinin geliştirilmesi için makine öğrenmesi ve derin öğrenme adımları uygulanmıştır. Veri madenciliği, sonuçları tahmin etmek için büyük veri kümeleri içindeki anormallikleri, örüntüleri ve ilişkileri bulma süreci olarak tanımlanabilir (SAS, 2021b). Veriden bilgi keşfi olarak da bilinen veri madenciliği, büyük veri kümelerinden örüntüleri ve diğer değerli bilgileri ortaya çıkarma sürecidir (IBM, 2021a). Veri madenciliği yöntem ve teknikleri ile hedef veri seti tanımlanabileceği gibi makine öğrenmesi algoritmaları kullanılarak tahminler de yapılabilir (IBM, 2021a). Makine öğrenmesi ve derin öğrenme yapay zekanın alt kümeleri olarak kabul edilmektedir (IBM, 2021c; Zhang, 2020). Makine öğrenmesi, insanların öğrenme şeklini taklit etmek için veri ve algoritmaların kullanımına odaklanmaktadır (IBM, 2021c). Makine öğrenmesinde algoritmalar, sınıflama ve tahmin yapmak için eğitilir ve bu içgörüler karar verme sürecini yönlendirmek amacıyla kullanılır (IBM, 2021c). Makine öğrenmesinde, bir uzmanın algoritma içindeki özelliklerin hiyerarşisini belirlemesi gerekirken, derin öğrenme işleminin bu yönünü otomatikleştirir (IBM, 2021b). Derin öğrenme, sürecin özellik çıkarma parçasının çoğunu otomatikleştirir ve insan müdahalesini en aza indirir (IBM, 2021c).

3.4.2.1.1. Verilerin hazırlanması ve veri keşfi

Verilerin hazırlanması ve veri keşfi süreci, tahmin modelinin geliştirilmesi için veri setinin oluşturulması ve veri ön işleme aşamalarından oluşmaktadır.

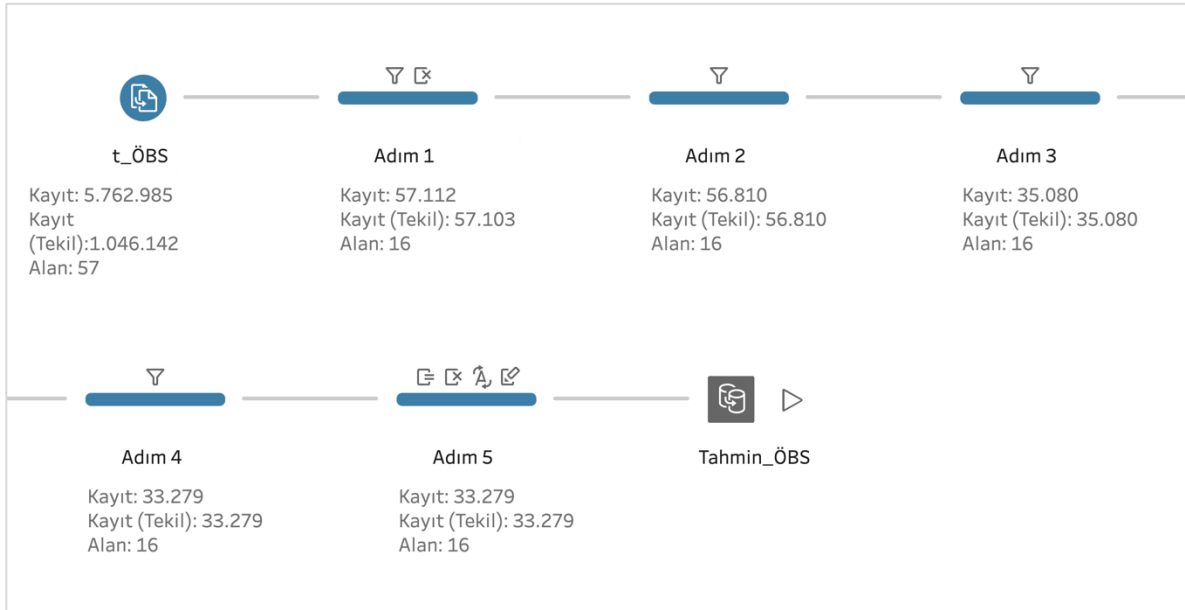
Veri setinin oluşturulması

Öğrenenlerin 2019-2020 öğretim yılı Güz döneminde BIL101U dersindeki akademik performanslarının tahmin edilmesinde kullanılacak veri setinin oluşturulması için t_ODFö_DS, t_TF, t_ODF ve t_ÖBS ve bunlardan elde edilen tablolar kullanılmıştır. Bu tablolarda yapılan veri temizleme, dönüştürme ve birleştirme işlemlerinin ardından “Tahmin Modeli Tablosu (t_TM)” oluşturulmuştur. İlk düzenlemeler t_ODFö_DS’de yapılmıştır. Bu tablo, öğrenenlerin 20 Ocak 2020’ye kadar olan tüm derslerdeki faaliyetlerini kapsamaktadır. Tablo 23 alan, 2.482.424 toplam kayıt ve 602.381 tekil kayıttan oluşmaktadır. Birinci adımda ders kodu BIL101U olan kayıtlar filtrelenmiş, diğer derslere ait kayıtlar veri setinden çıkarılmıştır. Adım 2’de 14 farklı malzeme türü verisine dayalı olarak Toplam Malzeme Erişim Sayısı hesaplanmıştır. Toplam malzeme erişim sayısı 0 ve 1 olan kayıtlar veri setinden çıkarılmıştır. Adım 3’te ek videolar, ders tanıtım videosu ve yakın plan video malzemelerinin toplam erişim sayısı tüm kayıtlar için 0 olduğundan dolayı bu alanlar veri setinden çıkarılmıştır. Adım 4’te kısa video ve etkileşimli video erişim sayısı alanları birleştirilerek yeni bir alan oluşturulmuştur. Adım 5’te İlk Oturum Haftası alanı Güz döneminin haftaları baz alınarak dönüştürülmüş ve iki farklı alan oluşturulmuştur. Bu işlemlerin ardından Tahmin_ODFö isimli yeni bir tablo oluşturulmuştur. t_ODFö_DS tablosunda yapılan işlemler Görsel 3.13’te özetlenmiştir.



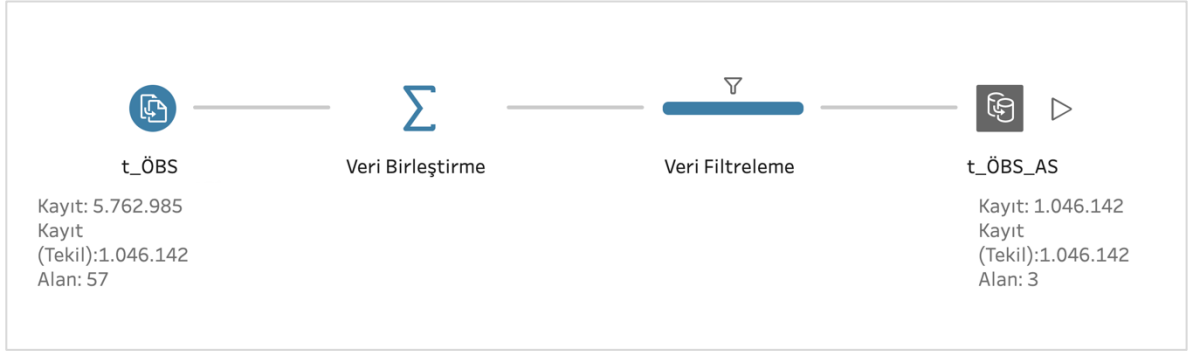
Görsel 3.13. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-I

Görsel 3.13'teki düzenlemelerin ardından t_ÖBS'de veri temizleme ve dönüştürme işlemleri yapılmıştır. Bu tabloda, 2019-2020 öğretim yılı Güz döneminde kayıtlı olan öğrenenlerin demografik verileri ve ders bazlı akademik performans puanları yer almaktadır. Tablo 57 alan, 5.762.985 toplam kayıt ve 1.046.142 tekil kayıttan oluşmaktadır. Bu tabloda öncelikle tahmin modelinde yer almayacak 41 alan veri setinden çıkarılmış ve ders kodu BIL101U olan kayıtlar seçilmiştir. Adım 2'de harf notu hesaplanmayan kayıtlar veri setinden çıkarılmıştır. Adım 3'te final notu hesaplanmayan ve geçersiz olan kayıtlar veri setinden çıkarılmıştır. Adım 4'te ara sınav notu hesaplanmayan kayıtlar veriden çıkarılmıştır. Adım 5'te öğrenenlerin diğer derslerden aldığı ara sınav notlarının ortalaması yeni bir alan olarak hesaplanmıştır. Bu işlemlerin ardından Tahmin_ÖBS isimli yeni bir tablo oluşturulmuştur. t_ÖBS tablosunda yapılan işlemler Görsel 3.14'te özetlenmiştir.



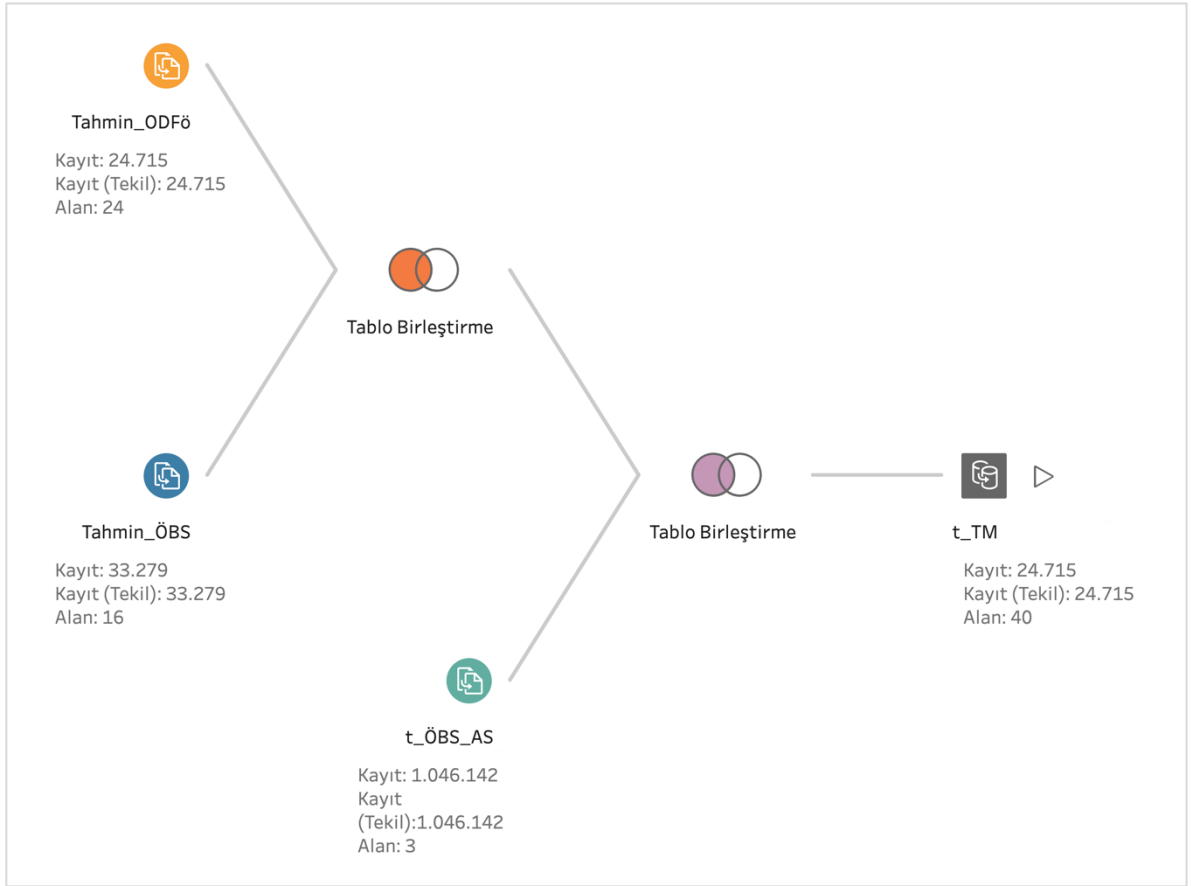
Görsel 3.14. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-II

Bu işlemlerden sonra öğrenenlerin t_ÖBS'deki kayıtları, öğrenci numarası baz alınarak birleştirilmiş ve öğrenenlerin tüm derslerdeki ara sınav not ortalamalarını gösteren hesaplanmış bir alan oluşturulmuştur. Bu işlemlerin ardından yeni bir tablo oluşturulmuştur (Görsel 3.15). t_ÖBS_AS isimli bu tabloda ara sınav notu olmayan 45 öğrenenin not değeri tüm öğrenenlerin ortalaması olan 48,66 ile değiştirilmiş ve yeni bir alan oluşturulmuştur.



Görsel 3.15. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-III

Temizleme ve dönüştürme işlemlerinin ardından Tahmin_ODFö, Tahmin_ÖBS ve t_ÖBS_AS birleştirilmiştir. Tabloların birleştirilmesi Tahmin_ODFö tablosundaki öğrenci numaraları baz alınarak gerçekleştirilmiştir. Bunun sonucunda 40 alan ve 24.715 kayıttan oluşan yeni bir veri seti elde edilmiştir. Bu veri seti “Tahmin Modeli Tablosu (t_TM)” olarak isimlendirilmiştir (Görsel 3.16).

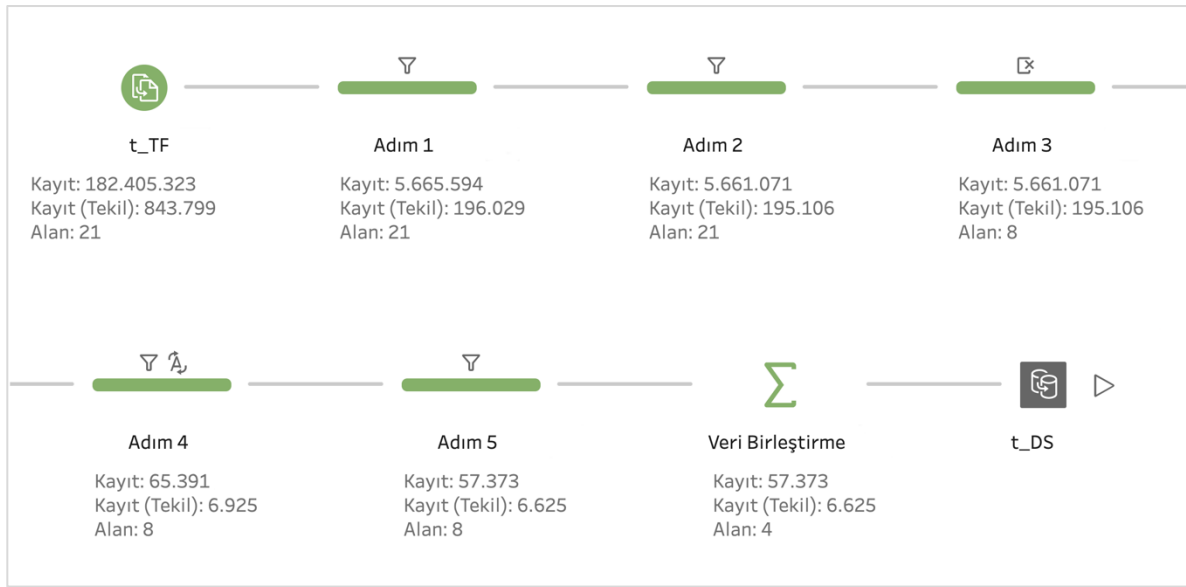


Görsel 3.16. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-IV

Birleştirme işleminden sonra harf notu olmayan kayıtlar veri setinden çıkarılmıştır. t_TM tablosundaki bölümler yeni bir alanda sözel, eşit ağırlık ve sayısal olarak gruplandırılmıştır. Bu işlemlerin sonrasında t_TM tablosu, 41 alan ve 18.595 kayıttan oluşmaktadır.

t_TM tablosu hazırlandıktan sonra öğrenenlerin deneme sınavlarına ilişkin veriler tabloya eklenmiştir (Görsel 3.17). Öğrenenlerin deneme sınavı ortalama puanlarının elde edilmesi için t_TF tablosunda çalışılmıştır. Bu tablo tarih bazlı olarak öğrenenlerin ilgili dönemdeki tüm hareketlerini içermektedir. Tablo 21 alan, 182.405.323 toplam kayıt ve 843.799 tekil kayıttan oluşmaktadır. Bu tabloda Adım 1’de faaliyet türü, deneme sınavı olan kayıtlar seçilmiştir. Adım 2’de 20 Ocak 2020’den sonra yapılan deneme sınavı verileri veri setinden çıkarılmıştır. Adım 3’te analizde kullanılmayacak 13 alan veriden çıkarılmıştır. Adım 4’te ders kodu BIL101U olan kayıtlar filtrelenmiş, diğer derslere ait kayıtlar veri

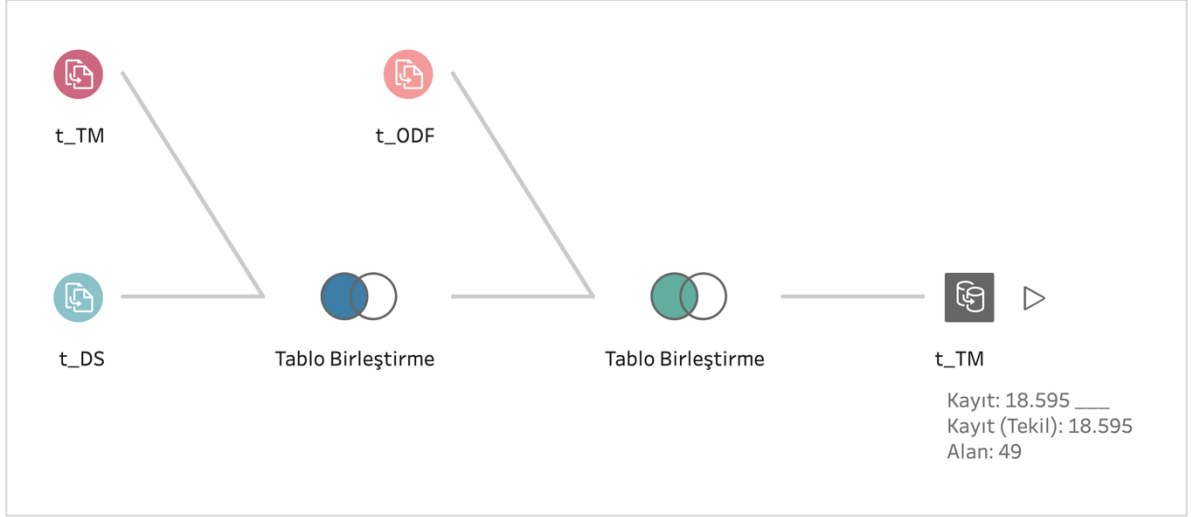
setinden çıkarılmıştır. Adım 5'te deneme sınavı notu 0 olan kayıtlar veri setinden çıkarılmıştır. Adım 6'da öğrenenlerin farklı deneme sınavlarına ilişkin verileri öğrenci numaraları gruplanarak birleştirilmiştir. Deneme sınavı ortalama puanı ve toplam deneme sınavı sayısı hesaplanmıştır. Deneme sınavı puanı hesaplanan öğrenenlerin puan ortalamaları 64,35; bu öğrenenlerin ara sınav puan ortalamaları ise 65,82'dir. Bu nedenle deneme sınavı ortalama puanı hesaplanmayan öğrenenler için deneme sınavı ortalama puanı yerine ara sınav puanları kullanılmıştır.



Görsel 3.17. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-V

Tahmin modelinde kullanılmak üzere son olarak öğrenenlerin haftalık malzeme kullanım durumları analiz edilmiştir. Bunun için t_ODF kullanılmıştır. Bu tabloda öğrenenlerin ders ve oturum bazlı öğrenme malzemeleri erişim durumları yer almaktadır. Buradaki oturum tarihleri ilgili dönemin haftaları bağlamında gruplandırılmış ve BIL101U dersindeki öğrenme malzemeleri kullanım durumları hesaplanmıştır. Buna göre bir kayıt haftası ve ikisi ekle sil haftası olmak üzere 30 Eylül 2019-20 Ocak 2020 tarihleri arasında 16 haftaya ait öğrenme malzeme kullanım veri seti oluşturulmuştur. Bu düzenlemenin ardından BIL101U malzeme erişimi olan hafta sayısı, malzeme erişim düzeyi ve sınav dönemi giriş alanları oluşturulmuştur. Bu alanlar t_TM tablosuna eklenmiştir (Görsel 3.18). Sınav dönemi giriş alanı hariç burada sözü edilen hesaplamalar diğer derslerdeki oturum ve öğrenme

malzemeleri erişim durumları için de yapılmış ve tabloya 4 alan daha eklenmiştir. Yapılan bu işlemlerin sonrasında, Tahmin Modeli Tablosunda 49 alan ve 18.595 kayıt yer almaktadır.



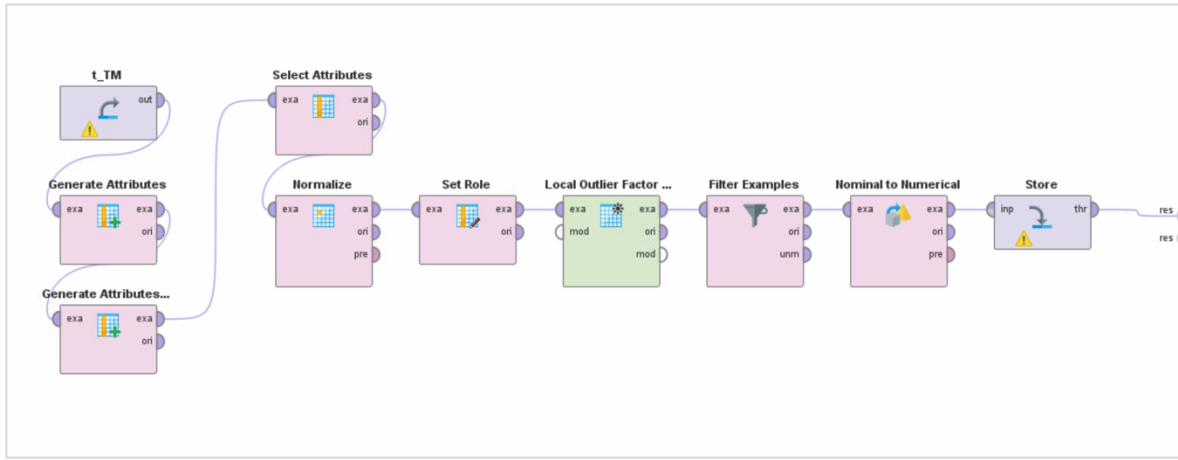
Görsel 3.18. Öğrenen performanslarının tahmin edilmesi veri hazırlama süreci-VI

Tahmin modelinin geliştirilmesi için makine öğrenmesi ve derin öğrenme algoritmaları kullanılmıştır. t_{TM} veri seti ile yapılan analizlerde tahmin gücü en yüksek %60 olarak elde edilmiştir. Tahmin gücünün yükseltilmesi için yapılabilecek çalışmalardan biri, sentetik veri üretmek yerine, veri setinden çıkarılan verilerin de analizde yer almasının var olan verinin doğasını daha iyi yansıtacağı düşünülmüştür. Bu nedenle, harf notu hesaplanmayan öğrenenler hariç diğer öğrenenlerin verileri veri setine yeniden eklenmiş ve veri dönüştürme işlemleri yeniden gerçekleştirilmiştir. Bu işlemlerin sonucunda t_{TM} , 49 alan ve 56.810 kayıttan oluşmaktadır. Tahmin modeli geliştirme çalışması, bu veri seti ile gerçekleştirilmiştir.

Veri ön işleme süreci


t_{TM} veri setinde sayısal değerler üzerinde min-maks normalizasyonu gerçekleştirilmiştir. Bu çalışmadaki öznitelik değerleri normal dağılım göstermediği ve min-maks normalizasyonu verilerin orijinal dağılımını koruduğu için bu normalleştirme türü tercih edilmiştir (Rapidminer, 2021b). Minimum değer 0, maksimum değer ise 1 olarak girilmiştir. Böylece tüm öznitelik değerleri 0-1 aralığında yer alacak şekilde

normalleştirilmiştir. Normalleştirme işleminin ardından aykırı değerlerin belirlenmesi için RapidMiner Studio’da yer alan Local Outlier Factor (LOF) operatörü ile kayıtların aykırılık değerleri hesaplanmıştır. LOF, veri kümesindeki her nesne için aykırılık derecesini göstermektedir. LOF, her bir nesnenin yalnızca sınırlı bir komşuluğunun dikkate alınması açısından yereldir ve yoğunluğa dayalı kümeleme ile ilişkilidir (Breunig, 2000; Goldstein ve Uchida, 2016). Aykırılık değeri 1,5’un üstündeki 5.299 kayıt filtrelenmiştir. Bu işlem sonucunda veri setinde 51.511 kayıt yer almıştır. Daha sonra kategorik özniteliklerde kukla kodlama (dummy coding) yapılmıştır. Böylece kategorik değerler sayısallaştırılmıştır. Yapılan işlemler Görsel 3.19’da sunulmuştur.



Görsel 3.19. Tahmin modeli veri setinde veri ön işleme süreci

Veri ön işleme sürecinde özniteliklerin kalite ölçümleri de yapılmıştır. Bu işlemde kararlılık (stability) değerleri 0,90’dan yüksek çıkan Oturum Açılan İlk Hafta, eDers, Canlı Ders Kayıtları ve Deneme Sınavı erişim sayısı öznitelikleri veri setinden çıkarılmıştır. Kararlılık değerinin yüksek olması o alandaki değerlerin neredeyse aynı olduğunu göstermektedir. Veri ön işleme sürecinde öznitelikler arasındaki ilişkileri gösteren korelasyon matrisi, Şekil 3.7’de sunulmaktadır.



Şekil 3.7. Görselleştirilmiş korelasyon matrisi

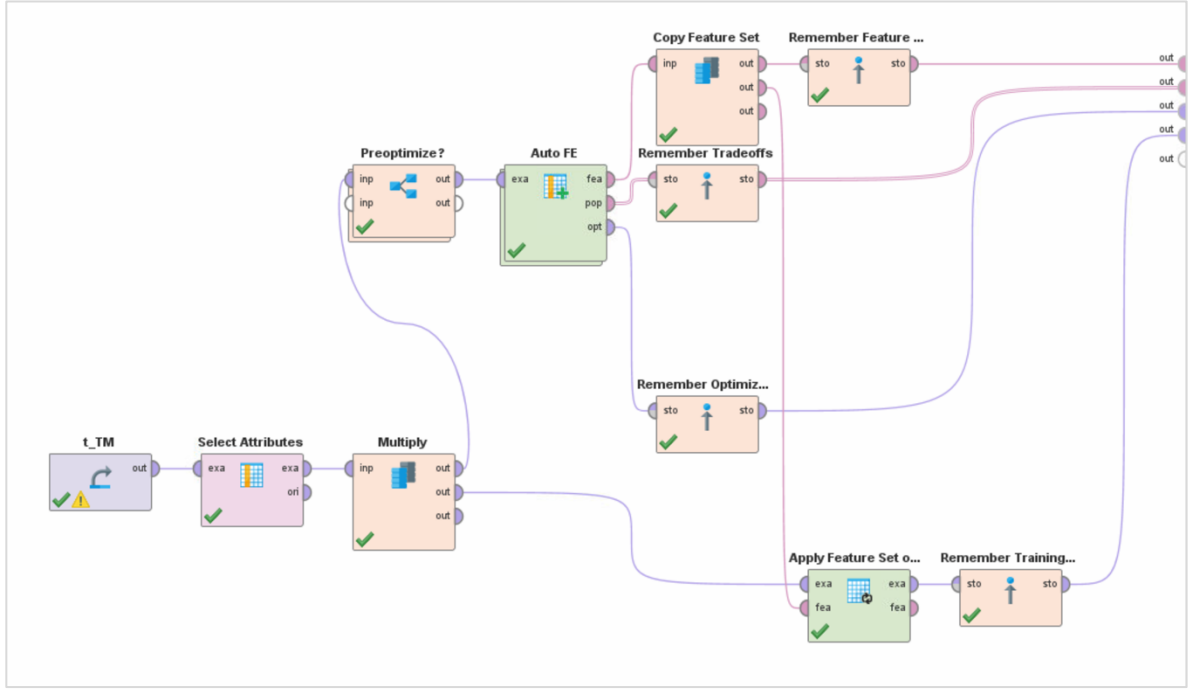
Şekil 3.7 incelendiğinde, Toplam Süre ve Yaş özniteliklerinin diğerleriyle arasında düşük düzeyde ilişki olduğu görülmektedir. Oturum Açma Sayısı, Toplam Faaliyet Sayısı, Günlük Ortalama Oturum Açma Sayısı, Oturum Açılan Gün Sayısı gibi özniteliklerin arasındaki ilişkinin ise güçlü olduğu görülmektedir.

3.4.2.1.2. Verilerin modellenmesi

Bu aşamada öznitelik mühendisliği (feature engineering) ve tahmin modelinde kullanılan algoritmaların özellikleri değerlendirilmektedir.

Öznitelik mühendisliği süreci

Öznitelik mühendisliği sürecinde tahmin modelinin geliştirilmesinde kullanılacak özniteliklerin belirlenmesi için RapidMiner Studio'da yer alan otomatik öznitelik mühendisliği (automatic feature engineering) operatörü kullanılmıştır. Bu operatör, öznitelik seçimi ve öznitelik oluşturmayı kapsayan otomatik bir özellik mühendisliği süreci gerçekleştirmektedir (RapidMiner, 2021b). Operatör, en iyi öznitelik kümelerini bulmak için çok amaçlı bir evrimsel algoritma kullanmaktadır. Burada sadece öznitelik seçimi yapılması işaretlenmiştir. Öznitelik seçim sürecinde yapılan işlemler, Görsel 3.20'de özetlenmiştir.



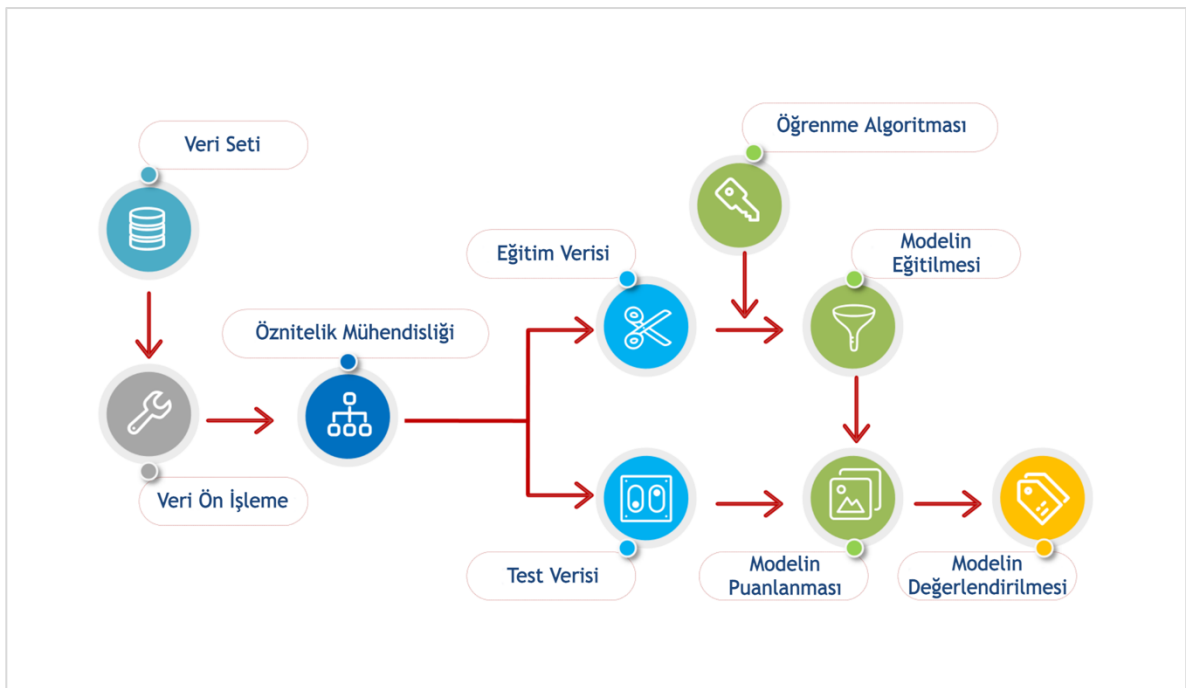
Görsel 3.20. Otomatik öznelik mühendisliği süreci

Bu analiz ile tahmin modelinin oluşturulması için kullanılacak öznelikler belirlenmiştir. Otomatik öznelik mühendisliği sonucunda 11 öznelik belirlenmiştir:

- Ara Sınav Notu
- Sınava Girme Oranı
- Oturum Açılan Gün Sayısı_Tamamı
- Toplam Faaliyet Sayısı_Tamamı
- Toplam Faaliyet Sayısı_BIL101U
- İnfografik Erişim Sayısı
- Günlük Ortalama Oturum Açma Sayısı_Tamamı
- Günlük Ortalama Oturum Açma Sayısı_BIL101U
- Çıkmış Sınav Soruları Erişim Sayısı
- Ders Kitabı Erişim Sayısı
- Ünite Özeti Erişim Sayısı

Gözetimli Öğrenme (Supervised Learning)

Öğrenenlerin akademik performanslarının tahmin edilmesi için makine öğrenmesi yöntemlerinden biri olan gözetimli öğrenme algoritmaları ve derin öğrenme kullanılmıştır. Gözetimli öğrenmede verileri sınıflandırmak ya da sonuçları tahmin etmek için etiketlenmiş veri kümeleri kullanılmaktadır (IBM, 2021c). Gözetimli öğrenme sürecinde eğitim, test ve doğrulama veri setleri ile modeller eğitilir, test edilir ve doğrulukları değerlendirilir. Gözetimli öğrenme süreci, Görsel 3.21’de sunulmaktadır.



Görsel 3.21. Gözetimli öğrenme süreci

Bu çalışmada öğrenenlerin akademik performanslarının tahmin edilmesi amacıyla Generalized Linear Model, Logistic Regression, Naive Bayes, Fast Large Margin, Decision Tree, Random Forest ve Gradient Boosted Trees gözetimli öğrenme algoritmaları kullanılmıştır:

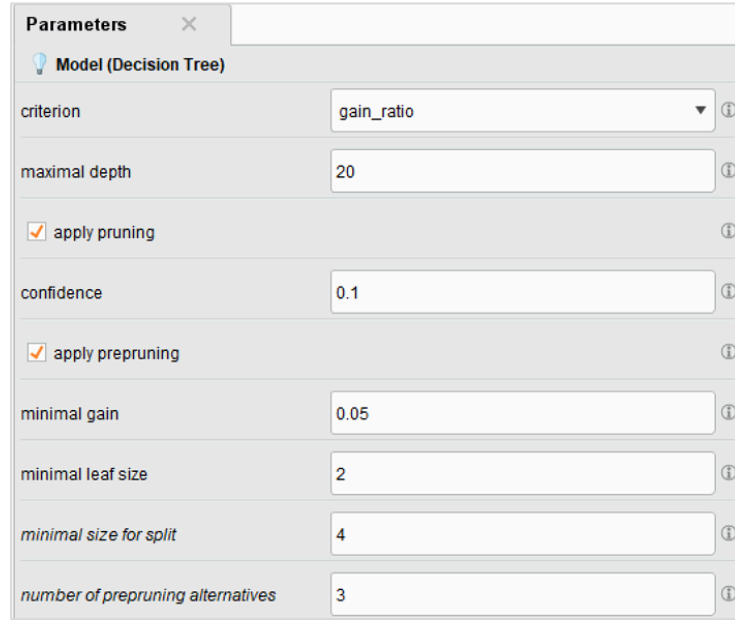
- **Generalized Linear Model (GLM):** GLM, zengin bir regresyon modelleri sınıfıdır (Tan vd., 2014). Bu modelde lineer regresyon, lojistik regresyon ve Poisson regresyonu birleştirilmektedir (Han vd. 2012; Tan vd., 2014). Bu modelde yinelemeli ağırlıklı regresyon tekniği, parametrelerin maksimum olabilirlik

tahminlerini elde etmek için kullanılmaktadır (Nelder ve Wedderburn, 1972). Algoritma, olabirlik fonksiyonunun logaritmasını (log-likelihood) maksimize ederek genelleştirilmiş lineer modelleri verilere uyarlamaktadır (RapidMiner, 2021d). Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan GLM algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örneklem seçeneği işaretlenmiştir. Aile (family) parametresi çok sınıflı, çözücü (solver) parametresi ise otomatik olarak ayarlanmıştır.

- **Logistic Regression (LR):** Lojistik regresyon, kategorik sınıfların tahmin edilmesinde kullanılan bir yöntemdir. Lojistik regresyon, iki ya da çok sınıflı olmak üzere iki grupta incelenebilir (Jurafsky ve Martin, 2021). Lojistik regresyonda, sınıf koşullu olasılıkları hakkında herhangi bir varsayımda bulunulmadan sonsal olasılıklar hesaplanarak sınıflar belirlenmektedir (Tan vd., 2014). Diğer bir ifade ile algoritma, verileri bir lojistik fonksiyona uydurarak bir olayın meydana gelme olasılığını tahmin etmektedir (Microsoft, 2021). Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan LR algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örneklem seçeneği işaretlenmiş, çözücü (solver) parametresi ise otomatik olarak ayarlanmıştır.
- **Naive Bayes (NB):** NB, olasılıksal sınıflandırma modellerinden biridir (Duda ve Hart, 1973; Langley ve Sage, 1994; Langley vd., 1992). NB sınıflandırıcıları, bir öznitelik değerinin belirli bir sınıf üzerindeki etkisinin diğer özniteliklerin değerlerinden bağımsız olduğunu (sınıf koşullu bağımsızlık) varsaymaktadır (Han vd., 2012). Bu algoritmada öznitelik vektörü tarafından tanımlanan belirli bir örneğe en olası sınıf atanmaktadır (Rish, 2001). Bu sınıflandırıcı, eğitim verilerinden, sınıf etiketi verilen her bir özniteliğin koşullu olasılığını öğrenmekte ve olasılık değeri en yüksek durumlara göre sınıflandırma yapmaktadır (Friedman vd., 1997). Algoritmada ilk adımda ön olasılık ve ikinci adımda sınıf koşullu olasılığı hesaplanmakta ve bunun ardından Bayes Teoremi kullanılarak sonuçlar tahmin edilmektedir (Kotu ve Deshpande, 2014). Bu çalışmada tahmin modelinin

geliştirilmesinde kullanılan NB algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örneklem seçeneği işaretlenmiş ve modelde Laplace düzeltmesi işaretlenmiştir.

- **Fast Large Margin (FLM):** FLM algoritması, tahmin sürecinde lineer destek vektörü öğrenme şemasına dayalı olarak marj öğrenici uygulamaktadır (RapidMiner, 2021e). Çalışma şekli, Support Vector Machine (SVM) algoritmasına benzemektedir. Bu algoritmanın çıktıları, SVM ve lojistik regresyon uygulamaları ile benzerlik göstermekle birlikte algoritma milyonlarca örnek ve nitelik içeren veri setleri üzerinde çalışabilmektedir (RapidMiner, 2021e). Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan FLM algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örneklem seçeneği işaretlenmiş, çözücü (solver) parametresi ise L2 SVM Dual olarak ayarlanmıştır. Epsilon değeri 0,01 ve C değeri 10 ise olarak girilmiştir.
- **Decision Trees (DT):** DT, verileri girdi özniteliklerinin değerlerine dayalı olarak daha saf alt kümelere bölmektedir (Kotu ve Deshpande, 2014). DT kök düğüm, iç düğüm ve yaprak düğümden oluşan hiyerarşik bir yapı sunmaktadır (Tan vd., 2014). Bir ağaçta en üstteki düğüm kök düğümdür (Han vd., 2012). Kökün altında iç düğümler, iç düğümlerin altında ise yaprak düğümler yer almaktadır. Tahmin modeli oluşturulurken belirlenen durdurma kriterleri karşılanana kadar yeni düğümlerin oluşturulması tekrarlanmaktadır (RapidMiner, 2021f). Her gözlem değeri, bir yaprağa ulaşına kadar bölme kuralına göre dallanma devam etmekte, bu süreç tamamlandığında ağaç yapısı tamamlanmaktadır (RapidMiner, 2021f). Kökten bir yaprak düğüme kadar izlenen yollar sınıf tahminini oluşturmaktadır (Han vd., 2012). Bu algorithmada çıktı modeli, yeni etiketlenmemiş verilerin tahmini için kullanılabilen bir ağaç çerçevesidir (Kotu ve Deshpande, 2014). Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan DT algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örneklem seçeneği işaretlenmiştir. Girilen diğer parametre değerleri ise Görsel 3.22’de sunulmuştur.



Parameters	
Model (Decision Tree)	
criterion	gain_ratio
maximal depth	20
<input checked="" type="checkbox"/> apply pruning	
confidence	0.1
<input checked="" type="checkbox"/> apply prepruning	
minimal gain	0.05
minimal leaf size	2
minimal size for split	4
number of prepruning alternatives	3

Görsel 3.22. DT algoritması parametre değerleri

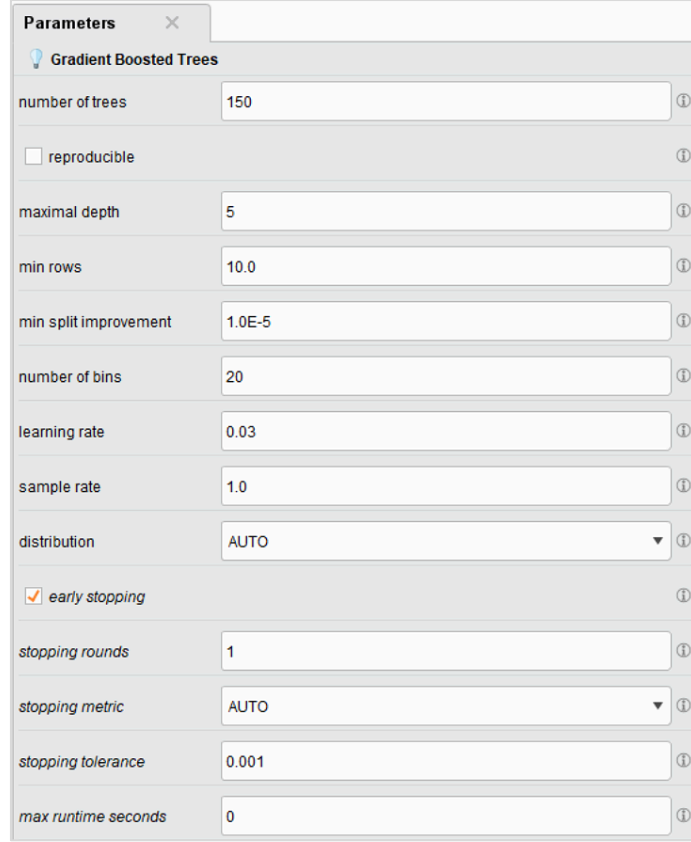
- **Random Forest (RF):** RF algoritması (Breiman, 2001), özellikle karar ağacı sınıflandırıcıları için tasarlanmış bir topluluk öğrenmesi yöntemidir (Tan vd., 2014). Random Forest, Breiman (2001) tarafından “her ağacın, ormandaki tüm ağaçlar için bağımsız olarak ve aynı dağılımla örneklenen rastgele bir vektörün değerlerine bağlı olduğu tahmin edicilerinin bir kombinasyonu” olarak tanımlanmaktadır. RF algoritmasında, birbiriyle ilişkili karar ağaçları topluluğu oluşturularak genelleme performansını iyileştirmek amaçlanmaktadır (Tan vd., 2019). Bu algoritma, torbalama (bagging) yöntemine dayanmaktadır (Friedman vd., 2008). Bu algoritmada her ağaç, ormandaki tüm ağaçlar için bağımsız olarak ve aynı dağılımla örneklenen rastgele bir vektörün değerlerine bağlıdır (Han vd., 2012). Sınıflandırma sırasında, her ağaç oy verir ve böylece en popüler sınıf döndürülür (Han vd., 2012). Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan RF algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örnekleme seçeneği işaretlenmiştir. Girilen diğer parametre değerleri ise Görsel 3.23’te sunulmuştur.

Parameter	Value
number of trees	100
criterion	gain_ratio
maximal depth	10
apply pruning	<input type="checkbox"/>
apply prepruning	<input type="checkbox"/>
random splits	<input type="checkbox"/>
guess subset ratio	<input checked="" type="checkbox"/>
voting strategy	confidence vote
use local random seed	<input type="checkbox"/>

Görsel 3.23. RF algoritması parametre değerleri

- **Gradient Boosted Trees (GBT):** GBT algoritması, regresyon ve sınıflandırma ağacı modellerinin bir topluluğudur (Friedman, 2001). Bu algoritma, kademeli olarak iyileştirilmiş tahminler yoluyla tahmin modelleri üreten, ileriye dönük bir öğrenme topluluğu yöntemidir (Click vd., 2015). Bu yöntemde aşamalı olarak zayıf öğreniciler, güçlü öğrenicilere dönüştürülmektedir. GBT algoritmasında gradyan tabanlı optimizasyon ve yükseltme araçları bir araya getirilmiştir (Click vd., 2015). Bu algoritmada yeni temel öğrenicilerin tüm toplulukla ilişkili kayıp fonksiyonunun negatif gradyanı ile maksimum düzeyde ilişkilendirilecek şekilde oluşturulması hedeflenmektedir (Natekin ve Knoll, 2013). Algoritmada güçlendirme, ağaçların doğruluğunu artırmaya yardımcı olan esnek ve doğrusal olmayan bir regresyon prosedürü ile gerçekleştirilmektedir (Click vd., 2015). Bu algoritmada ağaçları güçlendirmek için öncelikle sıralı olarak zayıf sınıflandırma algoritmaları kullanılarak karar ağaçları oluşturulmaktadır (RapidMiner, 2021c). Buradaki hata oranları düzeltilerek yeni ağaçlar üretilmektedir. Yeni ağaçların üretimine gerek kalmadığı noktada algoritma sona erer ve tahmin modeli geliştirilmiş olur. Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan GBT algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan

eşit oranda kayıt olması için tabakalı örnekleme seçeneği işaretlenmiştir. Girilen diğer parametre değerleri ise Görsel 3.24'te sunulmuştur.

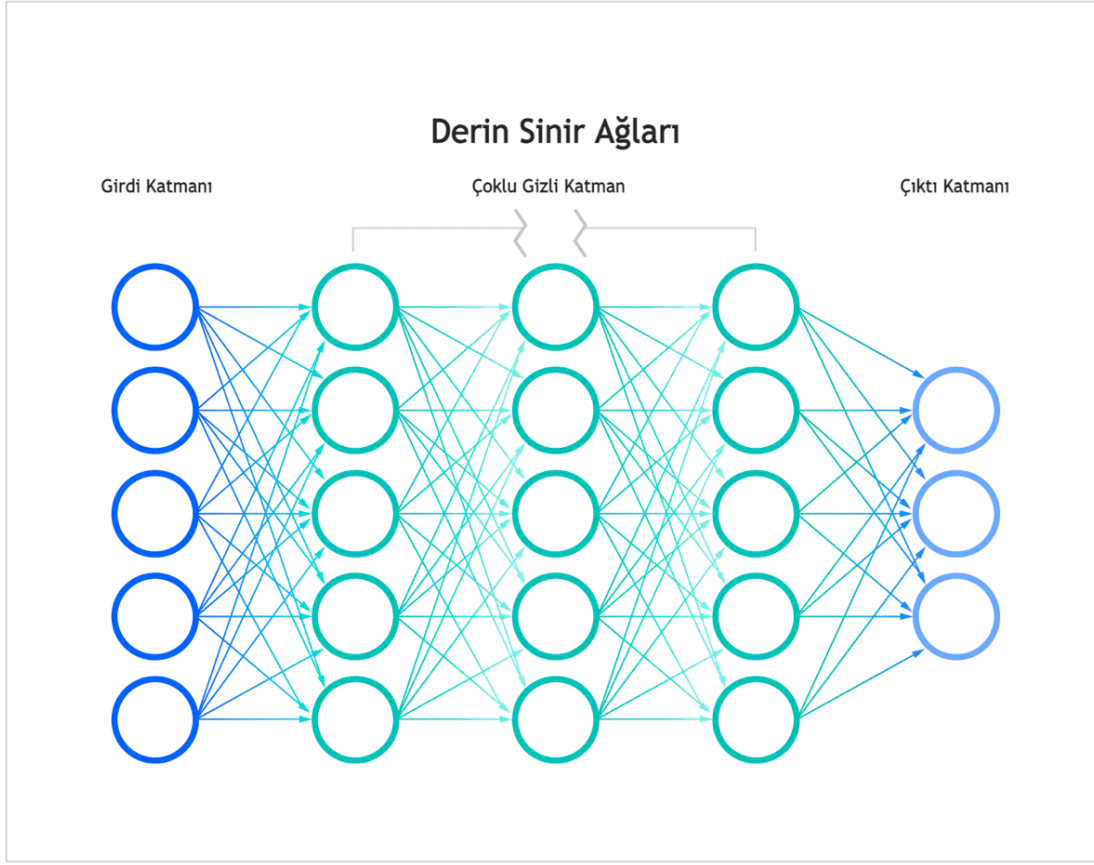


Parameter	Value
number of trees	150
reproducible	<input type="checkbox"/>
maximal depth	5
min rows	10.0
min split improvement	1.0E-5
number of bins	20
learning rate	0.03
sample rate	1.0
distribution	AUTO
early stopping	<input checked="" type="checkbox"/>
stopping rounds	1
stopping metric	AUTO
stopping tolerance	0.001
max runtime seconds	0

Görsel 3.24. GBT algoritması parametre değerleri

Derin Öğrenme

Öğrenenlerin akademik performanslarının tahmin edilmesi için makine öğrenmesi yöntemlerinden biri olan gözetimli öğrenme algoritmaları ve derin öğrenme kullanılmıştır. Derin öğrenme, makine öğrenmesinin bir alt kümesi olarak ifade edilebilir. Derin öğrenme, insan beyninin bilgiyi işleme, öğrenme ve dış uyaranlara yanıt verme biçimine dayanmaktadır (Zaccone, 2016). Derin öğrenme, büyük verideki örüntüleri öğrenmek için bilgi işlem gücündeki ilerlemeleri ve özel sinir ağları türlerini birleştirmektedir (SAS, 2021a). Derin öğrenme algoritmaları, yapay sinir ağlarından oluşmaktadır. Buradaki “derin” kelimesi, sinir ağlarındaki katmanların derinliğini vurgulamaktadır (IBM, 2021b). Görsel 3.25'te derin sinir ağı yapısı sunulmaktadır (IBM, 2021b).



Görsel 3.25. *Derin sinir ağı yapısı*

Bu çalışmada öğrenenlerin akademik performanslarının tahmin edilmesi amacıyla gözetimli öğrenme algoritmalarına ek olarak RapidMiner Studio üzerinde H₂O tarafından geliştirilen Deep Learning operatörü kullanılmıştır:

- **Deep Learning (DL-Derin Öğrenme):** H₂O'nun Derin Öğrenme ağı, geri yayılım kullanılarak stokastik gradyan inişi metodu ile eğitilmiş çok katmanlı bir ileri beslemeli yapay sinir ağına dayanmaktadır (H₂O, 2021). Standart bir sinir ağı, her biri gerçek değerli aktivasyon üreten birçok basit ve bağlantılı nörondan oluşmaktadır (Zhang, 2020). Modern yapay sinir ağları, sığ ve derin sinir ağları olarak ikiye ayrılmaktadır (Zhang, 2020). Sığ sinir ağları bir giriş katmanı, bir veya birkaç gizli katman ve bir çıkış katmanından oluşurken, derin sinir ağları birçok gizli katman içermektedir (Nguyen vd., 2019; Tan vd., 2014; Zhang, 2020).

H₂O'nun Derin Öğrenme ağı Tanh, Rectifier, ExpRectifier ve Maxout aktivasyon fonksiyonlarına sahip nöronlardan oluşan çok sayıda gizli katman içerebilmektedir (H₂O, 2021). Bu çalışmada tahmin modelinin geliştirilmesinde kullanılan DL algoritmasında eğitim ve test veri kümelerinin oluşturulmasında her gruptan eşit oranda kayıt olması için tabakalı örneklem seçeneği işaretlenmiştir. Gözlemlerin %85'i eğitim, %15'i ise test için ayrılmıştır. Aktivasyon fonksiyonu olarak ExpRectifier (Exponential Rectifier Linear Unit Function) seçilmiştir. Bu fonksiyon, ağ çok katmandan oluştuğu ve hız avantajı nedeniyle tercih edilmiştir. Bunun yanı sıra, Rectified Linear Unit fonksiyonunda geri yayılım sırasında öğrenme işleminin olmadığı durumlar yaşanabilmektedir. Bu nedenle bu durumun üstesinden gelebilen ExpRectifier, aktivasyon fonksiyonu olarak seçilmiştir. Analize 200, 100 ve 50 nörondan oluşan 3 gizli katman eklenmiştir. Girilen diğer parametre değerleri ise Görsel 3.26'da sunulmuştur.

Parameters	
Deep Learning	
activation	ExpRectifier
hidden layer sizes	Edit Enumeration (3)...
<input checked="" type="checkbox"/> reproducible (uses 1 thread)	
<input checked="" type="checkbox"/> use local random seed	
local random seed	1992
epochs	10.0
<input checked="" type="checkbox"/> compute variable importances	
train samples per iteration	-2
<input checked="" type="checkbox"/> adaptive rate	
epsilon	1.0E-8
rho	0.99
<input checked="" type="checkbox"/> standardize	
L1	1.0E-5
L2	0.0
max w2	10.0
loss function	Automatic
distribution function	AUTO
<input checked="" type="checkbox"/> early stopping	
stopping rounds	1
stopping metric	AUTO

Görsel 3.26. DL algoritması parametre değerleri

3.4.2.1.3. Modellerin Değerlendirilmesi

Bu çalışmada öğrenenlerin akademik performanslarının tahmin edilmesi amacıyla Generalized Linear Model, Logistic Regression, Naive Bayes, Fast Large Margin, Decision Tree, Random Forest, Gradient Boosted Trees ve Deep Learning algoritmaları kullanılmıştır. Bu algoritmalar ile elde edilen modellerin değerlendirilmesinde hata matrisi (confusion matrix), çapraz doğrulama (cross-validation) ve RapidMiner Studio'da yer alan Performance (Classification) operatörü kullanılmıştır. Hata matrisi, gerçek değerler ve tahmin edilen değerlerin kombinasyonunu içermektedir. Bu matristeki verilere dayalı olarak doğruluk

(accuracy) değeri hesaplanmaktadır. Çapraz doğrulama operatörü, bir modelin pratikte ne kadar doğru performans göstereceğini tahmin etmek için kullanılmaktadır (RapidMiner, 2021g). Bu operatörün eğitim ve test olmak üzere iki alt süreci bulunmaktadır (RapidMiner, 2021g). Modelin performansı ise test aşamasında ölçülmektedir (RapidMiner, 2021g). Performance (Classification) operatörü ise, sınıflandırma görevlerinin istatistiksel olarak performanslarının değerlendirilmesi için kullanılmaktadır (RapidMiner, 2021h).

3.4.3. Normatif Analitik Aşaması

Normatif analitikte “*Ne yapmalıyız?*” sorusu ile ilgilenilmektedir. Bunun için tanımlayıcı ve tahmin edici analitiklere dayalı olarak olası eylemler keşfedilmekte ve önerilmektedir (IBM, 2017). Bu analitik türünde çözüme odaklanılmaktadır. “*Olası en iyi sonuç nedir, belirli alanlarda değişkenlik göz önüne alındığında en iyi sonuç nedir?*” sorularına yanıt aranan normatif analitik (IBM, 2017) ile kişi bazlı eylemler planlanabilmekte, böylece kişiler için en uygun öneriler ve eylem planları oluşturulabilmektedir. Normatif analitikler sonucunda iş kuralları, organizasyon modelleri ve optimizasyon çalışmaları geliştirilebilmektedir.

Araştırmanın bu üçüncü ve son aşamasında Araştırma Sorusu 4 ve 5’e yanıt aranmıştır. Bu aşamada PDP’nin geliştirilmesi, öğrenenlere performansları hakkında geri bildirimler verilmesi ve müdahalede bulunulması amaçlanmaktadır. PDP, 2020-2021 öğretim yılı Güz döneminde tasarlanmış ve aynı yıl Bahar döneminde Temel Bilgi Teknolojileri II dersinde öğrenenlerin kullanımına sunulmuştur. Bu aşamada geliştirilen kurallar ile öğrenen gruplarına farklı erken müdahale stratejileri uygulanmıştır. Belirlenen erken müdahale stratejileri; kişi bazlı motivasyonel geri bildirim mesajı göndermek, PDP’de öğrenenlerin durumu hakkında bilgi sunmak, ders ve sınavlar ile ilgili hatırlatmalar sunmak, sınav sonrası geri bildirim vermek, pekiştireç ve çalışma stratejilerine yönelik öneriler vermek olarak sıralanabilir.

3.4.3.1. Öğrenme analitikleri tabanlı performans değerlendirme panelinin geliştirilmesi

PDP’nin geliştirilmesi sürecinde ÖYS’nin yönetiminden ve geliştirilmesinden sorumlu yönetici, yazılımcı ve tasarımcılar ile görüşmeler yapılmış ve ÖYS’ye entegre olarak

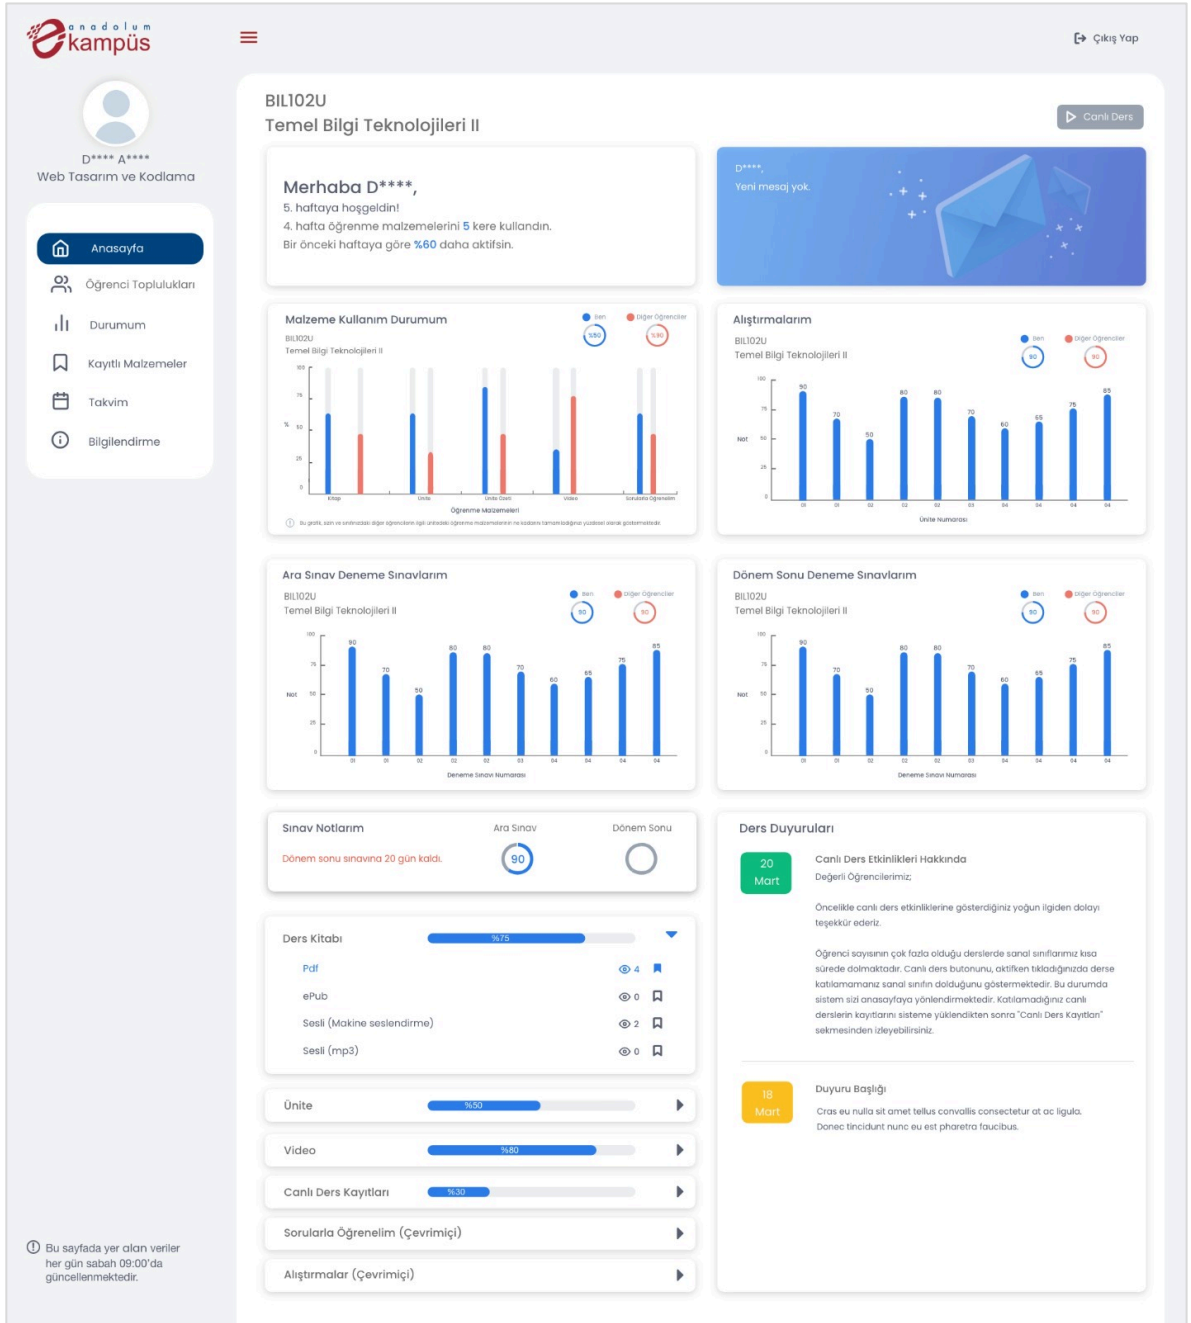
çalıřacak bir PDP geliřtirilmiřtir. PDP geliřtirilme sũrecinde dũngũsel bir sũreç izlenmiřtir. Bu dũngũsel sũreçte, hazırlanan tasarımlar ũzerinde iyileřtirmeler yapılması amaçlanmıřtır. PDP'nin Temel Bilgi Teknolojileri II dersinin içinde yer almasına karar verilmiřtir. Dersin içinde ۆğrenme malzemeleri ve duyurular yer almaktadır. PDP'nin ekranın en ũstũnde yer almasının uygun olacađı deđerlendirilmiřtir. ۆğrenme malzemelerinin konumunun sayfanın çok fazla alt bۆlũmlerinde kalmaması tasarım sũrecinde ۆn plana alınmıřtır. Ayrıca yapılan tasarım masaũstũ uygulamalar ve mobil ortamlar gibi farklı ekran boyutlarına sahip ortamlarda da kullanılabilieceđinden, tasarımın boyutuna dikkat edilmiřtir. Bu nedenle belirlenen temel performans gۆstergelerinin bir bakıřta kolayca anlařılmasına ve bu gۆsterge ve gۆrsel unsurların tek bir ekranda sunulmasına olanak sađlayacak tasarımın yapılması hedeflenmiřtir.

3.4.3.1.1. ۆğrenme analitikleri tabanlı performans deđerlendirme paneli taslak tasarımların hazırlanması

PDP geliřtirme sũrecinde ۆncelikle alanyazındaki çalıřmalar incelenmiřtir. Daha sonra Anadolu eKampũs'ũn yapısı ve ۆYS veri ambarında yer alan veriler incelenerek temel performans gۆstergeleri belirlenmiřtir. PDP'de yer almasına karar verilen bileřenler:

- ۆğrenme davranıřlarına yۆnelik ۆzet bilgi,
- ۆğrenme malzemeleri eriřim bilgileri,
- Sınavlardan alınan puanlar ve
- Geri bildirim alanlarıdır.

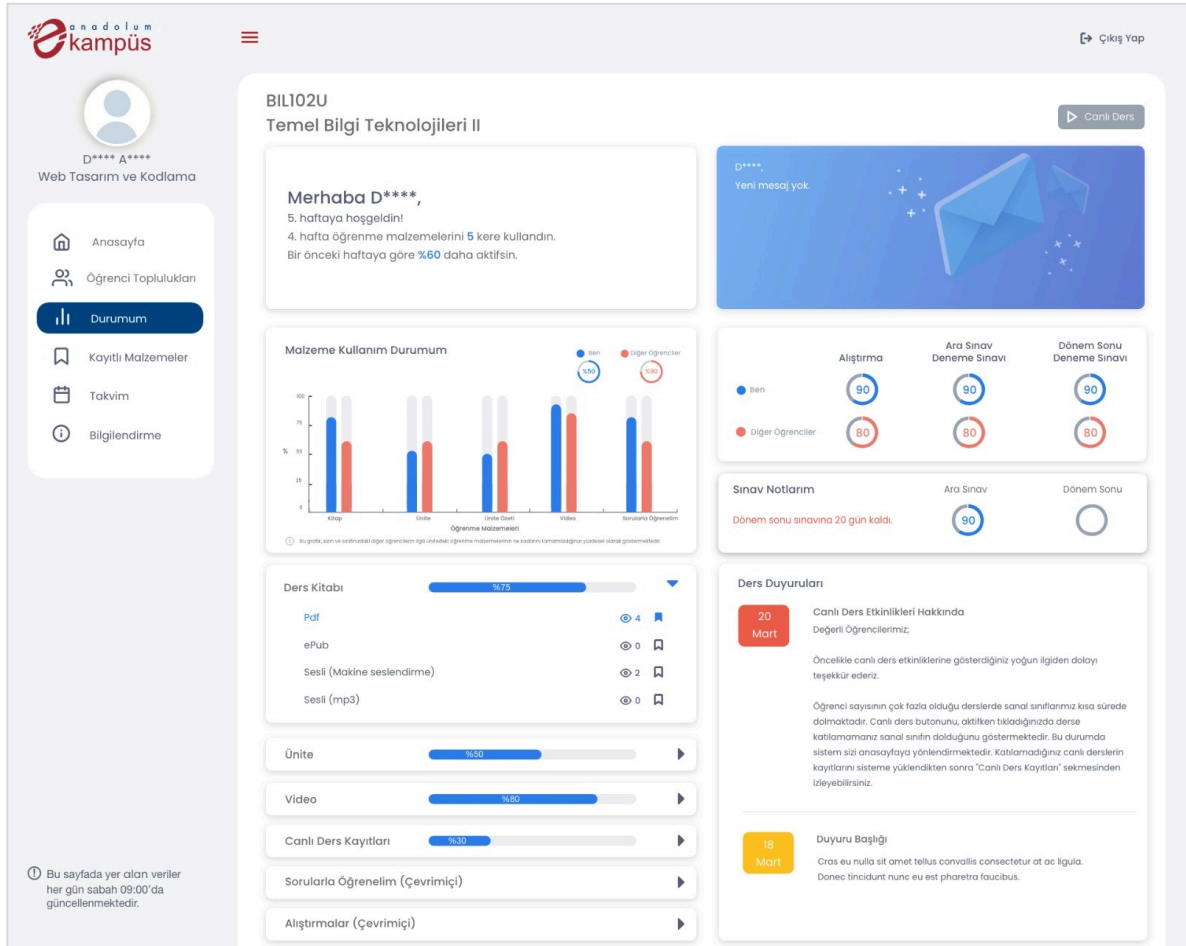
Bu bileřenler bađlamında temel performans gۆstergeleri; ۆğrenenlerin ۆğrenme malzemeleri eriřimleri, deneme sınavı ve alıřtırma sınavlarından aldıkları puanlar ve sınav puanları olarak belirlenmiřtir. Bu bileřenlerin ve performans gۆstergelerinin belirlenmesinin ardından PDP'nin taslak tasarımları grafik yazılımları kullanılarak yapılmıřtır. Gۆrsel 3.27'de Taslak Tasarım I (PDP-I) sunulmuřtur.



Görsel 3.27. PDP taslak tasarımı-I

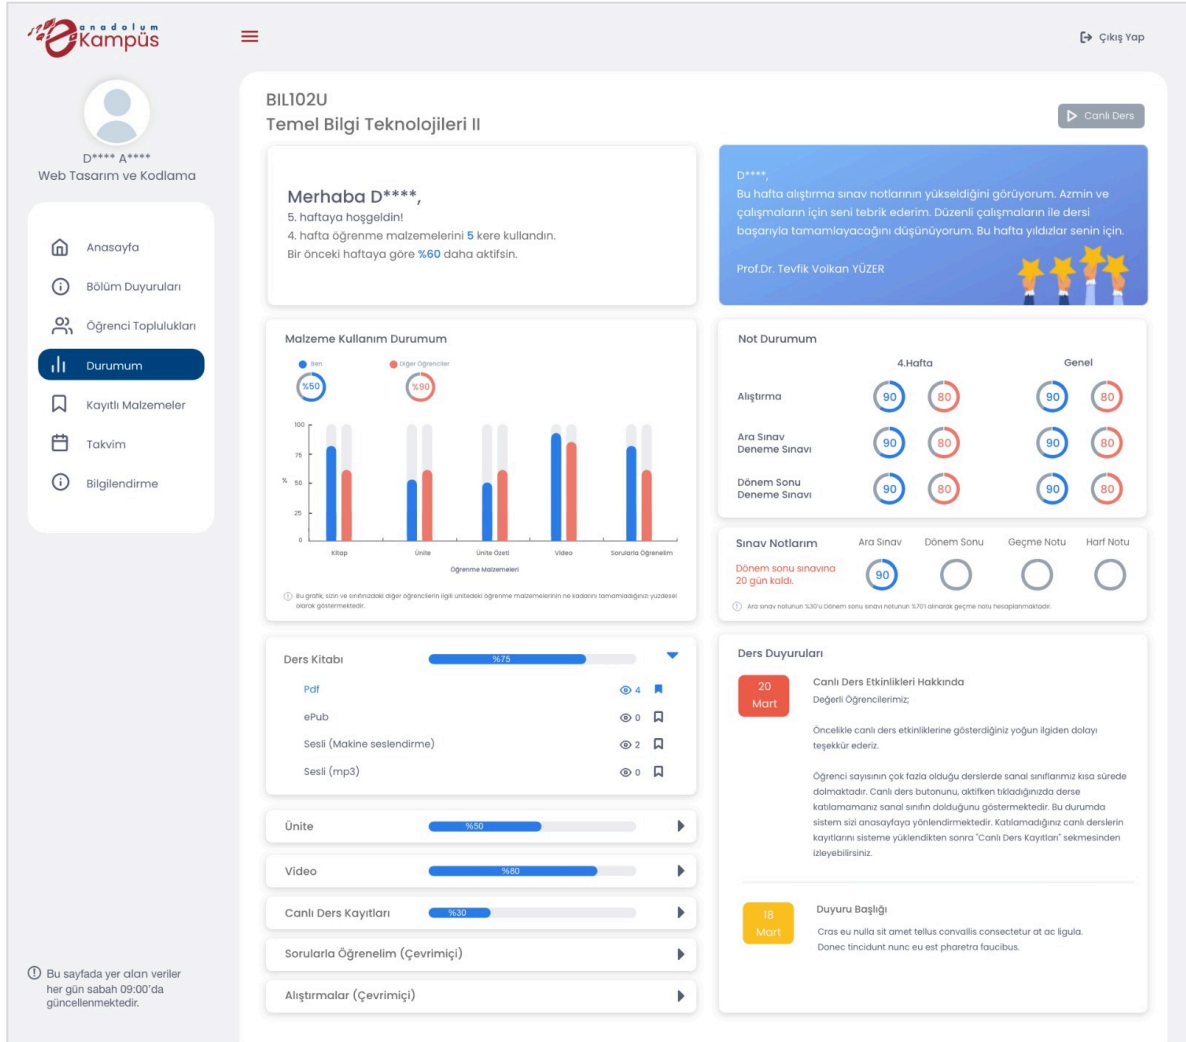
PDP-I, özetlenmiş verilerin metin olarak sunulduğu karşılama alanı, mesaj alanı, malzeme kullanım durumu, çözülen alıştırmaya sınavları ve alınan puanlar, deneme sınavlarından alınan puanlar (ara sınav ve dönem sonu sınavı) ve sınavlar alanı olmak üzere 7 bölümden oluşmaktadır. Malzeme kullanım durumları; kitap, ünite, ünite özeti, video ve

sorularla öğrenim malzemelerine ait veriler analiz edilerek oluşturulmuştur. Alıştırmalar ve deneme sınavları alanlarında öğrenenlerin çözdüğü 10 sınava ait ayrıntılı veriler ve ilgili tarihe kadar alınan ortalama puan verileri görüntülenebilmektedir. Öğrenenler kendi öğrenme süreçlerine ait bilgilerin yanı sıra ilgili derse kayıtlı diğer öğrenenlerin de ortalama kullanım ve puan değerlerini görüntüleyebilmektedirler. Veriler dönem başından itibaren ilgili güne kadar olan kullanım ve not durumlarını göstermektedir. PDP-I’de alanların fazla olması nedeniyle hem görüntünün anlaşılmasının zor olduğu hem de öğrenme malzemelerine erişmek için öğrenenlerin sayfayı kaydırmaları gerektiği göz önüne alınarak alıştırmalar ve deneme sınavlarına ilişkin grafiklerde değişiklik yapılmıştır. Son 10 sınava ilişkin grafikler kaldırılmış ve bu 3 alan tek bir alanda özetlenmiştir. Buna ek olarak grafik tasarımları da farklılaştırılarak Taslak Tasarım II (PDP-II) hazırlanmıştır (Görsel 3.28).



Görsel 3.28. PDP taslak tasarım-II

PDP-II, 5 bölümden oluşmaktadır. PDP-I'den farklı olarak alıştırma, ara sınav deneme sınavı ve dönem sonu deneme sınavına ait öğrenenin ve diğer öğrenenlerin ilgili tarihe kadar olan not ortalamaları tek bir alanda birleştirilmiştir. PDP-II'de bu alandaki notlar ilgili hafta ve tüm dönem ortalaması olarak gruplanarak Taslak Tasarım III (PDP-III) hazırlanmıştır (Görsel 3.29).



Görsel 3.29. PDP taslak tasarım-III

3.4.3.1.2. *Veri altyapısının hazırlanması ve ÖYS entegrasyonu*

Taslak tasarımların hazırlanmasının ardından PDP'nin nihai halinin oluşturulması, verilerle bağlantı sağlanması ve ÖYS entegrasyonunun yapılması için bölümler ve içerikler üzerinde yeniden çalışılmıştır. Bu bağlamda yapılan düzenlemeler bu bölümde açıklanmıştır.

AÖS'ün yapısı göz önüne alındığında verilerin sunumunda hafta bazlı yapıdan son 7 günlük yapıya geçilmesinin daha uygun olacağı değerlendirilmiştir. Bu nedenle karşılama ve not durumu alanlarındaki haftalara ilişkin veriler son 7 gün ile değiştirilmiştir. Bununla birlikte karşılama bölümündeki mesaj, öğrenenin son 7 gün ve dönemlik olarak öğrenme malzemelerine kaç kere eriştiği ve en çok eriştiği öğrenme malzemesi türünü kapsayacak şekilde güncellenmiştir. Mesaj alanından yapılacak geri bildirimler için ÖYS ile bağlantılı mesaj girişinin yapılabileceği bir yapı tasarlanmıştır. Mesajlarda öğrenen adı ve ders sorumlusunun adının yer almasının uygun olacağı değerlendirilmiştir.

Malzeme kullanım durumu alanındaki öğrenme malzeme sayısı, PDP kullanılabilirliğinin ve anlaşılabilirliğinin azaltılmaması amacıyla 5 ile sınırlandırılmıştır. Bu sınırın belirlenmesindeki tek neden tasarımsal kaygılar değildir. AÖS'te malzemeler ünite bazlı olarak hazırlanmaktadır. Ancak alıştırmalar, canlı dersler, deneme sınavları gibi malzemeler ünite sayısından bağımsız olarak sınırsız sayıda yapılabilmektedir. Bu yapıdaki malzemelerin ünite sayısı sabit olan malzemelerle karşılaştırılması doğru olmayacağından bu alandaki grafikte kitap, ünite, ünite özeti, video ve sorularla öğrenelim malzemeleri yer almıştır. Kitap ve ünite benzer yapıdaki malzemeler olduğu için birleştirilmiş ve ünite grafikten çıkarılmıştır. Bu grafikte malzeme kullanım sayısı değil, toplam malzeme sayısı göz önüne alınarak kullanım oranları verilmiştir. Bunun yanı sıra benzer özellikteki malzemeler gruplanmış ve sistemde yer alan malzeme sayıları göz önüne alınarak kullanım oranının hesaplanabilmesi için bir formül geliştirilmiştir (Tablo 3.2).

Tablo 3.2. BIL102U toplam malzeme sayısının hesaplanması

Öğrenme Malzemesi	Açıklama	Malzemenin Maksimum Değeri
Kitap ve Ünite Metni	<ul style="list-style-type: none">• Kitap ve Ünite Metni aynı malzemelerdir. Bunları aynı birime getirebilmek için kitap, 8 malzeme olarak hesaplanmıştır. Sistemde yer alan kitap türleri; Kitap (pdf), Kitap (epub), Kitap (Daisy Seslendirme) ve Kitap (mp3)'tür. Öğrenen bu 4 malzemeden herhangi birine tıkladıysa ders kitabı sayısı 8 olarak hesaplanmıştır.• Ders kitabı yerine ünite metinlerine tıklandıysa tıklanan ünite sayısı baz alınmış ve ders kitabı erişimi olarak değerlendirilmiştir.• Öğrenen ilk iki maddede yer alan öğrenme malzemelerinden herhangi birine tıkladıysa ders kitabına erişmiş sayılmıştır.	8
Ünite Özeti ve Sesli Özet	<ul style="list-style-type: none">• Bu iki malzeme birbirinin aynısı olarak değerlendirilebilir.• Bu iki malzemeden herhangi birine erişen öğrenen ünite özetine ermiş sayılmıştır.	8
Video	<ul style="list-style-type: none">• Sistemde mikroanimasyon, konu anlatımı ve etkileşimli video olmak üzere 3 çeşit video yer almaktadır.• Mikroanimasyon sayısı erişim sayısına eş değer olarak alınmıştır. Toplam sayısı 8'dir.• Konu anlatımı ve etkileşimli video ise aynı malzeme olarak değerlendirilebilir. Bu yüzden bu iki video türünden birine tıklayan öğrenen bu malzemeye erişmiş sayılmıştır. Toplam sayısı 8 olarak kabul edilmiştir.	16
Canlı Ders ve Canlı Ders Kayıtları	<ul style="list-style-type: none">• Sistemde 11 tane canlı ders kaydı yer almaktadır. Burada öğrenenin canlı derse girememesi durumunda bu kayıtları izlemesi beklenmektedir. Haftalık olarak canlı derse katılan öğrenenlerin Canlı Ders malzemesine erişimi girdikleri canlı ders sayısı olarak kabul edilmiştir. Benzer şekilde kaydı izleyen öğrenenlerin de Canlı Ders malzemesine erişimleri izledikleri kayıt sayısı kadar olmalıdır. Burada toplama işlemi yapılmamış ikisine de erişildiyse sadece biri baz alınmıştır.	11
İnfografik	<ul style="list-style-type: none">• Sistemde yer alan malzeme sayısı hesaplamaya erişim sayısına eş değer olarak dahil edilmiştir.	8
Sorularla Öğrenelim	<ul style="list-style-type: none">• Sistemde yer alan malzeme sayısı hesaplamaya erişim sayısına eş değer olarak dahil edilmiştir.	8
Alıştırmalar	<ul style="list-style-type: none">• Öğrenen bu malzemeyi sınırsız bir şekilde kullanabilmektedir. Her üniteden en az 1 tane alıştırma çözülmesi yeterli sayılmıştır.	8
Deneme Sınavları	<ul style="list-style-type: none">• Çevrimiçi malzemelerdir.• Ara sınav ve dönem sonu sınavı için dörder deneme sınavı yapılması yeterli sayılmıştır.	8
Çıkmış Sınav Soruları	<ul style="list-style-type: none">• Sistemde yer alan malzeme sayısı baz alınmıştır.	16

Tablo 3.2'ye göre BIL102U Toplam Malzeme sayısı (BIL102U_{TMS}) aşağıdaki şekilde hesaplanmıştır:

$$\begin{aligned} \text{BIL102U}_{\text{TMS}} = & \text{Kitap} + \text{Ünite Özeti} + \text{Video} + \text{Canlı Ders} + \text{İnfografik} \\ & + \text{Çıkmış Sınav soruları} + \text{Sorularla Öğrenelim} + \text{Alıştırmalar} \\ & + \text{Deneme Sınavı (Ara Sınav)} + \text{Deneme Sınavı (Dönem sonu)} \end{aligned}$$

$$\text{BIL102U}_{\text{TMS}} = 8 + 8 + 16 + 11 + 8 + 16 + 8 + 8 + 4 + 4 = 91$$

“Malzeme Kullanım Durumum” bölümündeki hesaplamalar ve grafikler bu formüle dayalı olarak yapılmıştır. Malzeme türlerindeki dönüşüm göz önüne alındığında PDP’de 14 farklı öğrenme malzemesinin kullanımına yönelik veriler sunulmuş, 18 öğrenme malzemesi ise toplam kullanım yüzdelerinin hesaplanmasında kullanılmıştır.

Öğrenenlerin Malzeme Kullanım Durumu, Not Durumu, Sınav Durumu ve Karşılama bölümlerindeki verilerinin ve grafiklerinin elde edilmesi için ÖYS veri ambarında hesaplamalar yapılmıştır. Bunun için Microsoft SQL Server 2017 veritabanı ile ÖYS için oluşturulmuş olan veri ambarı kullanılarak PDP için gerekli veri ambarı alt kümeleri (data mart) oluşturulmuştur. Veri ambarı alt kümeleri, günlük planlanmış olup bir gün öncesine ait verileri özetleyerek ÖYS'ye veri sağlamaktadır. Veriler, .NET Core 3.0 ortamında geliştirilen web servisler ile ÖYS’ye aktarılmaktadır.

3.4.3.1.3. Geri bildirim bileşeninin geliştirilmesi

Araştırmada PDP üzerinden ders sorumlusunun adıyla belirlenen kurallara bağlı olarak öğrenenlere geri bildirim mesajları gönderilmiştir. Bu bölümde geri bildirim mesajlarının hazırlanma süreci ve mesajların ÖYS’de görüntülenebilmesi için hazırlanan web tabanlı ortam bileşenleri açıklanmaktadır.

Geri bildirim mesajlarının hazırlanması

Araştırmada erken müdahale sisteminin geliştirilmesinde ARCS-V (Attention, Relevance, Confidence, Satisfaction-Volition) motivasyon tasarım modeli temel alınarak

hazırlanan geri bildirim mesajları kullanılmıştır. Keller (1987) tarafından geliştirilen ARCS-V modeli, beklenti-değer kuramı, pekiştirme kuramı ve bilişsel değerlendirme kuramlarına dayanan etkileşim merkezli bir motivasyon modelidir. Bu model dikkat, ilişki, güven, doyum ve eylem kategorilerinden oluşmaktadır (Keller, 2010). Dikkat, öğrenenlerin ilgisinin çekilmesi ve öğrenme merakının güdülenmesi ile ilgilidir. İlişki, olumlu bir tutum sağlamak için öğrenenlerin bireysel hedeflerinin gerçekleştirilmesi olarak ele alınabilir. Güven, öğrenenlerin başarılı olacaklarına inanmaları ve olumlu beklentiler içerisinde olmalarını belirtmektedir. Doyum, öğrenenlerinin başarılarının desteklenmesi olarak ifade edilebilir. Eylem ise, problem durumlarında öğrenenlere gerekli stratejilerin sunulması ve çözüme yönelik becerilerin kazandırılmasıdır. Motivasyon temelli iletişim, ARCS-V tasarım modelinde en önemli motivasyonel ve öğretimsel araç olup (Uçar ve Kumtepe, 2016) araştırma kapsamında uygulanan motivasyonel erken müdahale stratejilerine ilişkin bilgiler, Tablo 3.3'te sunulmuştur (Uçar, 2016).

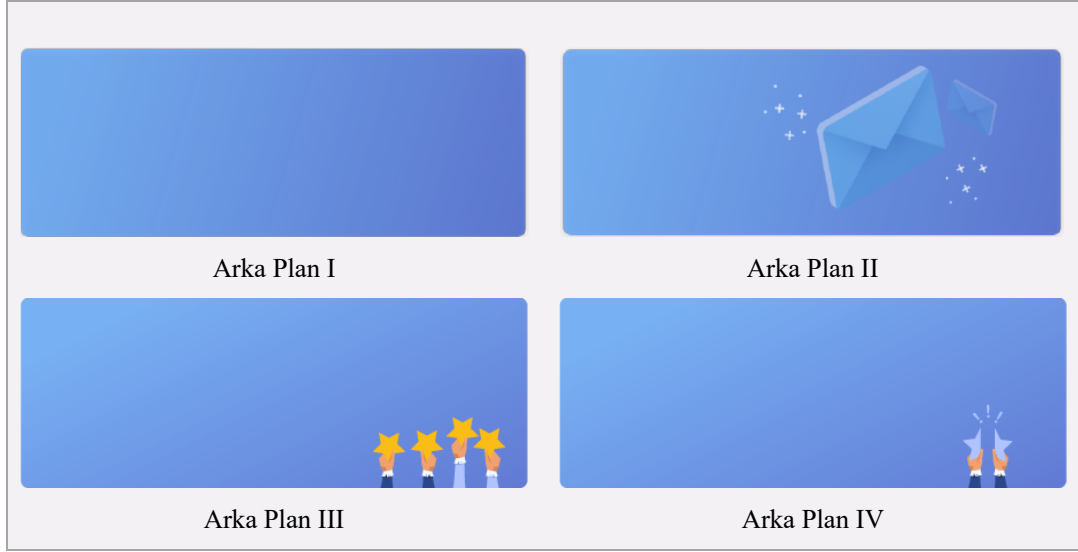
Tablo 3.3. *Motivasyonel erken müdahale stratejileri*

	Başta	Ortada	Sonda	Boyunca
A (Dikkat)	Hoş geldiniz mesajı	Konular ile ilgili dikkat çekici açıklamaların hazırlanması	-	Dikkat çeken mesaj ve ilgili tasarım unsurlarının kullanılması
R (İlişki)	Dersin öneminin anlatılması, geçmiş öğrenmelerin ve gelecekteki yaşamın dersle ilgili ilişkisinin hatırlatılması	Konunun öneminin vurgulanması	-	Haftanın konu içeriklerine göre mesaj gönderimi
C (Güven)	Dersin yapısı, ilerleme durumu, içerikler ve sınavlar hakkında bilgi verilmesi	Sınav tarihlerinin ve kapsamının hatırlatılması, ara sınav sonrası geri bildirim verilmesi	Dönem sonu sınavı sonrası geri bildirim verilmesi	Sınavlara yönelik bildirimler ve motive edici mesajların gönderilmesi
S (Doyum)	-	Öğrenenlere olumlu pekiştireçler verilmesi ve durumları hakkında geri bildirim sunulması	-	İlerleme durumuna dayalı olarak pekiştireç kullanılması, mesaj gönderilmesi, kontrol ve ilerleme durumunun sunulması
V (Eylem)	Öğrenenlerin çabalarının ne kadar önemli olduğunun vurgulanması, ÖYS'ye giriş yapma daveti, PDP kullanım daveti	Derse ve içeriklere erişmeyen, sınavlara katılmayan öğrenenlere bireysel mesaj ve SMS gönderilmesi, PDP'de uyarı verilmesi	-	Ders ve sınavlarla ilgili hatırlatma yapılması ve içerik kullanım davetlerinin yapılması

Araştırma kapsamında kullanılan pekiştireçler, motivasyonel ve bilgilendirici mesajlar olmak üzere iki kategori olarak planlanmıştır. Motivasyonel mesajlar, “Tebrikler! Çok iyi ilerleme gösteriyorsunuz.” gibi mesajları kapsamaktadır. Bilgilendirici mesajlar ise, öğrenenlerin ilerleme durumu göz önünde bulundurularak öğrenme süreci hakkında detaylı bilgilerin paylaşıldığı mesajlar olarak tasarlanmıştır.

Mesaj alanı arka plan görseli, mesaj içeriklerine bağlı olarak değişecek şekilde tasarlanmıştır. Bunun için 4 farklı arka plan görseli tasarlanmıştır (Görsel 3.30). Bu bağlamda varsayılan olarak I numaralı arka plan, mesaj olmaması durumunda II numaralı arka plan, öğrenenin ilerleme gösterdiği durumlarda motivasyon ve tebrik amacıyla oluşturulan

mesajlar için III numaralı arka plan, öğrenenin öğrenme malzemeleri kullanımında azalma ya da alıştırma ve deneme sınavı notlarında düşüş olduğunda uyarı göndermek amacıyla hazırlanan mesajlarda IV numaralı arka plan kullanılmıştır.



Görsel 3.30. Geri bildirim mesajlarında kullanılan arka plan örnekleri

Gerı bildirim mesajlarının gönderimine yönelik teknik altyapının hazırlanması

Gerı bildirim mesajlarının hazırlanması sürecine paralel olarak mesajların öğrenenlere ulaşması için gereken teknik altyapısı da geliştirilmiştir. Bu aşamada mesajların ÖYS’de görüntülenebilmesi için geliştirmeler yapılmıştır. Bunun için öncelikle PDP’de yer alacak bildirimlerin ve mesajların ÖYS ortamına aktarılması ile ilgili web servisler oluşturulmuştur. .NET Core 3.0 ortamında geliştirilen bir uygulama ile öğrenenlerin, hangi zaman aralığında ve hangi şekilde bildirim alacaklarına yönelik veri girişı gerçekleştirilmiştir. PDP’de görüntülenen mesajlar için önceden girilmiş bir kural listesine uygun olarak saklı yordamlar (stored procedure) hazırlanmıştır.

Kurallar				
#	Açıklama	Test	Test Sonucu	Uygula
1	Aktif öğrenciler içerisinde sisteme 10 kereden az giren öğrenciler	Test		Uygula
2	BIL102U dersine ilk girişte gösterilecek merhaba mesajı.	Test		Uygula
3	BIL102U dersine ilk girişte nasıl çalışılması gerektiğini anlatan mesaj	Test		Uygula
4	BIL102U Ders Tanıtım Videosu	Test		Uygula
5	BIL102U dersine yol gösterme mesajı	Test		Uygula
6	RULE-7 Haftada 3 kez derse giren ve 5 malzemeye tıklayan	Test		Uygula
7	RULE-8 Derse giriş yapıp 2'den az öğrenme malzemesi kullanan öğrenenler	Test		Uygula
8	RULE-9 Derse hiç giriş yapmayan öğrenenler	Test		Uygula
9	RULE-10 Derse hiç giriş yapmayan öğrenenler	Test		Uygula
10	RULE-11 Tüm öğrenciler	Test		Uygula
11	RULE-12 Tüm öğrenciler	Test		Uygula
12	RULE-13 1 Mart 2021 06:00-7 Mart 2021 23:59 tarihleri arasında BIL102U dersindeki malzemelere hiç tıklamayan öğrenciler	Test		Uygula
13	RULE-14 1 Mart 2021 06:00-7 Mart 2021 23:59 tarihleri arasında BIL102U dersindeki malzemelere sadece 1 kez tıklayan öğrenciler	Test		Uygula
14	RULE-15 1 Mart 2021 06:00-7 Mart 2021 23:59 tarihleri arasında BIL102U dersindeki malzemelere 2-9 (dahil) kez tıklayan öğrenciler	Test		Uygula
15	RULE-16 1 Mart 2021 06:00-7 Mart 2021 23:59 tarihleri arasında BIL102U dersindeki malzemelere 10 ve üzeri tıklayan öğrenciler	Test		Uygula

Görsel 3.31. Geri bildirim mesaj kuralları giriş ekranı

Mesajlar, Görsel 3.31’de yer alan kural listesinden ilgili kural seçildikten sonra uygulanabilmektedir. “Test” butonuna tıklandığında ilgili mesajı kaç öğrenenin göreceği takip edilebilmektedir. “Kuralı Uygula” butonuna tıklandığında ise mesaj giriş ekranı açılmaktadır. Mesaj oluşturma ekranı, Görsel 3.32’de verilmiştir. Mesajların arka planında yer alan görseller değişebilmektedir. Buna ek olarak mesajlara görsel ya da video eklenebilmektedir. Bu ekrandan mesajların sistemde kalma tarih aralığı da belirlenmektedir. Tüm mesajlar öğrenenlerin adına özel olarak gitmektedir. Bu bağlamda, farklı sistem kullanım örüntüsü gösteren öğrenenlere farklı mesajlar hazırlanmıştır. Kullanılabilecek farklı mesaj türleri; paneldeki mesaj alanında yer alacak mesajlar, pop-up olarak gösterilecek mesajlar ve SMS’tir. Mesaj oluşturulduktan sonra belirlendiği zaman aralığında mesaj içeriği öğrenenlere sunulmaktadır.

RULE-10 Derse hiç giriş yapmayan öğrenenler

Kural Açıklaması
RULE-10 Derse hiç giriş yapmayan öğrenenler

Kuraldaki Parametre Sayısı
0

Mesaj başlangıç tarihi:
03/12/2021

Mesaj bitiş tarihi:
03/12/2021

Mesaj Başlığı

LMS SMS e-Posta

Mesaj Arkaplanı
Boş

Mesaj Türü
Ders Popup Metin

Video Adresi

Resim Adresi

Seçmiş olduğunuz kuraldaki parametreleri metin içerisinde {rp} ile belirtiniz
Örnek
Merhaba Burak, harf notun AA
Merhaba {rp}, harf notun {rp}

Bildirim içeriğini giriniz:

Mesajı Oluştur

Görsel 3.32. Mesaj oluşturma ekranı

3.4.3.1.4. Öğrenme analitikleri tabanlı performans değerlendirme panelinin nihai tasarımı ve özellikleri

PDP taslak tasarımlarının hazırlanması, veri altyapısının hazırlanması, ÖYS entegrasyonunun gerçekleştirilmesi ve geri bildirim bileşeninin tasarlanmasının ardından ÖYS üzerinde PDP'nin nihai tasarımı oluşturulmuştur (Görsel 3.33). ÖYS'de panelin

tasarlanması için React framework kullanılmış, Jquery ile servisler çağırılmıştır. Grafikler ise HTML ve CSS altyapısı kullanılarak hazırlanmıştır.



Görsel 3.33. PDP nihai tasarımı

PDP, 5 bileşenden oluşmaktadır. Sol üstteki ilk bileşende öğrenene karşılama mesajı ve ilgili hafta Anadolu eKampüs'te gerçekleştirmiş olduğu çalışmaların özeti sunulmaktadır. Sol altta ise Malzeme Erişim Durumu yer almaktadır. Öğrenen buradan hem kendisinin hem de diğer öğrenenlerin malzeme kullanım durumunu takip edebilmektedir. Panelde yer alan veriler, her sabah saat 06.00'da güncellenmektedir. Sağ üstte ders sorumlusundan öğrenene özel olarak gönderilen mesajların yer aldığı bölüm bulunmaktadır. Bunun altında öğrenenin kendisinin ve diğer öğrenenlerin alıştırmaya ve deneme sınavı not ortalamalarını görebildiği alan yer almaktadır. Son olarak panelde öğrenenin sınavlardan aldığı notlar ve sınav tarihine yönelik hatırlatma mesajının yer aldığı alan yer almaktadır.

PDP'deki veriler, öğrenenlerin kendi verilerinden elde edilmekte olup mesajların öğrenenlerin kendisine özel olarak ders sorumlusu adıyla gönderilmesinin uygun olduğu değerlendirilmiştir. PDP, BIL102U dersine girildiğinde en üstte yer almaktadır. Öğrenme malzemeleri ve ders duyuruları ise PDP'nin altında yer almaktadır (Görsel 3.34). Öğrenenlerin malzemelere kolaylıkla erişebilmeleri için PDP sade ve öğrenenler için fayda sağlayacağı ve anlamlı olacağı değerlendirilen bileşenler kullanılarak yapılandırılmıştır.

The screenshot displays the PDP interface for the BIL102U course. The user is identified as D**** A****, a student in the 'Web Tasarım ve Kodlama' program. The course is 'BIL102U Temel Bilgi Teknolojileri II'. The interface includes a navigation menu on the left with options like 'Anasayfa', 'Öğrenci Toplulukları', 'Durumum', 'Kayıtlı Malzemeler', 'Takvim', and 'Bilgilendirme'. The main content area is titled 'Performans Değerlendirme Paneli' and contains several sections:

- Merhaba Dilek, 2. Haftadayız!**: A welcome message stating the user has accessed 39 materials in the last 7 days and 80 materials in the current period. It highlights 'Ünite Özeti' as the most accessed material and 'Video' as the most accessed material in the current period.
- Dersler Başlıyor!**: A section for course announcements, mentioning the start of the 'İlk konumuz İşletim Sistemleri Ünite metni üzerinde notlar olarak çalışmaya başlayabilirsiniz.' and the instructor 'Prof.Dr. Tevfik Volkan Yüzer'.
- Malzeme Erişim Durumu**: A bar chart comparing the user's material access (Ben) with other students (Diğer Öğrenciler) across four categories: Kitap, Ünite Özeti, Video, and Sorularla Öğrenelim. The user's scores are 6.80, 5.10, and 5.10 respectively.
- Not Durumu**: A table showing exam results for the last 7 days and overall. The user's scores are 70 for 'Ağırtma', 75 for 'Ara Sınav Deneme Sınavı', and 50 for 'Dönem Sonu Deneme Sınavı'. The overall scores are 0 for 'Ağırtma', 79.1 for 'Ara Sınav Deneme Sınavı', and 50 for 'Dönem Sonu Deneme Sınavı'.
- Sınav Notlarım**: A section for exam results, showing the user's score of 70 for 'Ara Sınav' and 0 for 'Dönem Sonu', 'Geçme Notu', and 'Harf Notu'.
- Ders Kitabı**: A list of course materials with progress bars: Pdf (96.75%), ePub (0%), Sesli (Makine seslendirme) (0%), and Sesli (mp3) (0%).
- Ders Duyuruları**: A section for course announcements, including a notice about the start of the course and a reminder to attend the course.

Görsel 3.34. PDP nihai tasarımının ÖYS entegrasyonu

3.4.3.2. *Öğrenme analitikleri tabanlı performans değerlendirme panelinin uygulanması*

Tasarımlama ve geliştirme süreçlerinin tamamlanmasının ardından PDP, 2020-2021 öğretim yılı Bahar dönemi boyunca Temel Bilgi Teknolojileri II (BIL102U) dersini alan öğrenenlere sunulmuştur. Uygulama, 17 hafta boyunca sürdürülmüştür. BIL102U dersi farklı bölümlerden öğrenenlerin bulunduğu ortak bir ders olduğu için uygulamanın gerçekleştirileceği ders olarak belirlenmiştir. Bu aşama, nicel bir araştırma yöntemi olan kontrol gruplu deneysel araştırma modeli ile desenlenmiştir. Deneysel araştırma modeli, değişkenler arasında neden-sonuç ilişkilerinin ortaya konulması ve karşılaştırmalar yapılması için kullanılmaktadır (Creswell, 2012). Bu model ile öğrenenlere uygulanan PDP'nin öğrenme sürecine etkilerinin test edilmesi planlanmaktadır. Burada yeni geliştirilen bir uygulamanın test edilmesi ve sonuçlarının değerlendirilmesi amaçlanmaktadır. Deney tasarımının gerçekleştirilmesi için öğrenenler, 2020-2021 eğitim-öğretim yılı Güz döneminde Temel Bilgi Teknolojileri I (BIL101U) dersindeki veriler kullanılarak deney ve kontrol gruplarına ayrılmıştır. Bu nedenle BIL101U ve BIL102U derslerinin her ikisinde de kayıtlı olan 26.753 öğrenene ait veriler analiz edilmiştir. Deney ve kontrol gruplarının belirlenmesi için öğrenenlerin BIL101U dersindeki öğrenme malzemeleri erişim ortalamaları ve dersi dönem sonu puanları kullanılmıştır. Öğrenenler bu değişkenler bağlamında 4 gruba ayrılmıştır. Daha sonra bu 4 grup kendi içinde seçkisiz (random) olarak deney ve kontrol gruplarına ayrılmıştır. Bunu işlemin yapılmasının nedeni deney ve kontrol grupları arasında ÖYS kullanımı ve akademik performans açısından benzerliğin sağlanmasıdır. BIL101U dersinde öğrenenlerin öğrenme malzemeleri erişim ortalamaları 9,8 ve dönem sonu not ortalamaları ise 64,9 olarak hesaplanmıştır. Bu değerler göz önüne alınarak 4 farklı alt grup oluşturulmuştur:

- **Yüksek Erişim Yüksek Not Grubu (G_YEYN):** Bu grup, öğrenme malzemeleri ortalama erişimleri 9,8 ve üstü, dönem sonu not ortalamaları 64,9 ve üstü olan öğrenenlerden oluşmaktadır.
- **Yüksek Erişim Düşük Not Grubu (G_YEDN):** Bu grup, öğrenme malzemeleri ortalama erişimleri 9,8 ve üstü, dönem sonu not ortalamaları 64,9'dan düşük olan öğrenenlerden oluşmaktadır.

- **Düşük Erişim Yüksek Not Grubu (G_DEYN):** Bu grup, öğrenme malzemeleri ortalama erişimleri 9,8'den düşük ve dönem sonu not ortalamaları 64,9 ve üstü olan öğrenenlerden oluşmaktadır.
- **Düşük Erişim Düşük Not Grubu (G_DEDN):** Bu grup, öğrenme malzemeleri ortalama erişimleri 9,8'den düşük ve dönem sonu not ortalamaları 64,9'dan düşük olan öğrenenlerden oluşmaktadır.

Alt grupların belirlenmesinin ardından öğrenenler seçkisiz olarak deney ve kontrol gruplarına atanmıştır. Bu işlem sonucunda deney grubunda 13.377, kontrol grubunda ise 13.376 öğrenen yer almaktadır (Tablo 3.4).

Tablo 3.4. *Alt gruplar bağlamında deney ve kontrol gruplarının dağılımı*

Alt Gruplar	Deney Grubu	Kontrol Grubu	Toplam	Yüzde
G_DEDN	2.233	2233	4.466	16,7
G_DEYN	6.001	6001	12.002	44,9
G_YEDN	1.137	1136	2.273	8,5
G_YEYN	4.006	4006	8.012	29,9
Genel Toplam	13.377	13.376	26.753	100

Deney tasarımında alt gruplar bağlamında BIL101U dersinde öğrenme malzemelerine erişim ve dönem sonu ortalama puanları bakımından deney ve kontrol gruplarının birbirinden istatistiksel olarak anlamlı bir farklılık göstermemeleri yani benzer özelliklerde olmaları beklenmektedir. Bunun için bağımsız örneklem t-testi analizleri yapılmıştır. Öncelikle G_YEYN açısından öğrenme malzemelerine erişim ve dönem sonu ortalama puan faktörleri deney ve kontrol grupları bağlamında incelenmiştir (Tablo 3.5).

Tablo 3.5. *G_YEYN bağımsız örneklem t-testi sonuçları*

Faktör	Grup Türü	n	\bar{x}	SS	t	df	p
Öğrenme Malzemelerine Erişim	Deney	4.006	30,65	24,77	0,452	8010	0,651
	Kontrol	4.006	30,40	24,03			
Dönem Sonu Ortalama Puan	Deney	4.006	84,23	9,40	0,043	8010	0,966
	Kontrol	4.006	84,22	9,24			

(\bar{x} : Ortalama; SS: Standart Sapma)

Tablo 3.5 incelendiğinde, G_YEYN için faktörlerin grup türü değişkeni açısından anlamlı bir farklılık göstermediği belirlenmiştir ($p>0,05$). Bu bağlamda, G_YEYN için deney ve kontrol grubundaki öğrenenlerin öğrenme malzemelerine erişim ve dönem sonu ortalama puan durumlarının istatistiksel olarak aynı düzeyde olduğu ifade edilebilir.

G_YEDN açısından öğrenme malzemelerine erişim ve dönem sonu ortalama puan faktörleri deney ve kontrol grupları arasında anlamlı bir farklılık olup olmadığını belirlemek için bağımsız örneklem t-testi yapılmıştır (Tablo 3.6).

Tablo 3.6. G_YEDN bağımsız örneklem t-testi sonuçları

Faktör	Grup Türü	n	\bar{x}	SS	t	df	p
Öğrenme Malzemelerine Erişim	Deney	1.137	32,11	26,24	0,136	2271	0,892
	Kontrol	1.136	31,96	25,53			
Dönem Sonu Ortalama Puan	Deney	1.137	51,30	12,55	-0,808	2271	0,419
	Kontrol	1.136	51,72	12,30			

(\bar{x} : Ortalama; SS: Standart Sapma)

Tablo 3.6 incelendiğinde, G_YEDN için faktörlerin grup türü değişkeni açısından anlamlı bir farklılık göstermediği belirlenmiştir ($p>0,05$). Bu bağlamda, G_YEDN için deney ve kontrol grubundaki öğrenenlerin öğrenme malzemelerine erişim ve dönem sonu ortalama puan durumlarının istatistiksel olarak aynı düzeyde olduğu ifade edilebilir.

G_DEYN açısından malzemelerine erişim ve dönem sonu ortalama puan faktörleri deney ve kontrol grupları arasında anlamlı bir farklılık olup olmadığını belirlemek için bağımsız örneklem t-testi yapılmıştır (Tablo 3.7).

Tablo 3.7. G_DEYN bağımsız örneklem t-testi sonuçları

Faktör	Grup Türü	n	\bar{x}	SS	t	df	p
Öğrenme Malzemelerine Erişim	Deney	6.001	2,03	2,64	0,537	12000	0,591
	Kontrol	6.001	2,00	2,63			
Dönem Sonu Ortalama Puan	Deney	6.001	84,25	9,04	-0,219	12000	0,827
	Kontrol	6.001	84,29	9,04			

(\bar{x} : Ortalama; SS: Standart Sapma)

Tablo 3.7 incelendiğinde, G_DEYN için faktörlerin grup türü değişkeni açısından anlamlı bir farklılık göstermediği belirlenmiştir ($p>0,05$). Bu bağlamda, G_DEYN için deney ve kontrol grubundaki öğrenenlerin öğrenme malzemelerine erişim ve dönem sonu ortalama puan durumlarının istatistiksel olarak aynı düzeyde olduğu ifade edilebilir.

G_DEDN açısından öğrenme malzemelerine erişim ve dönem sonu ortalama puan faktörleri deney ve kontrol grupları arasında anlamlı bir farklılık olup olmadığını belirlemek için bağımsız örneklem t-testi yapılmıştır (Tablo 3.8).

Tablo 3.8. *G_DEDN bağımsız örneklem t-testi sonuçları*

Faktör	Grup Türü	n	\bar{x}	SS	t	df	p
Öğrenme Malzemelerine Erişim	Deney	2.233	1,45	2,49	0,242	4464	0,809
	Kontrol	2.233	1,43	2,47			
Dönem Sonu Ortalama Puan	Deney	2.233	44,30	18,82	1,390	4464	0,164
	Kontrol	2.233	43,51	19,03			

(\bar{x} : Ortalama; SS: Standart Sapma)

Tablo 3.8 incelendiğinde, G_DEDN için faktörlerin grup türü değişkeni açısından anlamlı bir farklılık göstermediği belirlenmiştir ($p>0,05$). Bu bağlamda, G_DEDN için deney ve kontrol grubundaki öğrenenlerin öğrenme malzemelerine erişim ve dönem sonu ortalama puan durumlarının istatistiksel olarak aynı düzeyde olduğu ifade edilebilir.

Yapılan bağımsız örneklem t-testi sonuçları değerlendirildiğinde kontrol ve deney gruplarındaki öğrenenlerin oluşturulan alt gruplar (G_YEYN, G_YEDN, G_DEYN, G_DEDN) bağlamında öğrenme malzemelerine erişim ve dönem sonu ortalama puan durumlarının istatistiksel olarak aynı düzeyde olduğu görülmektedir.

Bu çalışmada deney ve kontrol gruplarının benzer özellikler göstermeleri, alt grupların ise kendi aralarında farklılaşmaları beklenmektedir. Alt grupların öğrenme malzemelerine erişim ve dönem sonu ortalama puan açısından anlamlı bir farklılık gösterip göstermediklerini belirlemek için tek yönlü ANOVA testi yapılmıştır. Yapılan analiz sonucunda Levene testi, grup değişkenine yönelik varyansların öğrenme malzemelerine erişim ve dönem sonu ortalama puan faktörü açısından homojen dağılmadığını göstermiştir

($p < 0,001$). Bu nedenle analizin yorumlanması aşamasında Brown-Forsythe istatistiği kullanılmıştır (Pallant, 2005). Sonuçlar, Tablo 3.9’da gösterilmiştir.

Tablo 3.9. Tek yönlü ANOVA testi sonuçları

Faktör	Alt Grup	n	\bar{x}	SS	F	p	Tamhane
Öğrenme Malzemelerine Erişim	G_YEYN	8.012	30,52	24,40	5127,707 (Brown-Forsythe)	0,000*	G_YEYN- G_DEYN
							G_YEYN- G_DEDN
	G_YEDN	2.273	32,03	25,88			G_YEDN- G_DEYN
							G_YEDN- G_DEDN
	G_DEYN	12.002	2,02	2,64			G_DEYN- G_YEYN
							G_DEYN- G_DEDN
							G_DEDN- G_YEYN
	G_DEDN	4.466	1,44	2,48			G_DEDN- G_YEDN
							G_DEDN- G_DEYN
Dönem Sonu Ortalama Puan	G_YEYN	8.012	84,22	9,32	13349,153 (Brown-Forsythe)	0,000*	G_YEYN- G_YEDN
							G_YEYN- G_DEDN
	G_YEDN	2.273	51,51	12,43			G_YEDN- G_YEYN
							G_YEDN- G_DEYN
	G_DEYN	12.002	84,27	9,04			G_YEDN- G_DEDN
							G_DEYN- G_YEDN
							G_DEYN- G_DEDN
	G_DEDN	4.466	43,90	18,92			G_DEDN- G_YEYN
							G_DEDN- G_YEDN
							G_DEDN- G_DEYN

(* $p < 0,001$; \bar{x} : Ortalama; SS: Standart Sapma)

Tablo 3.9’da grup değişkenleri açısından öğrenme malzemelerine erişim faktörünün anlamlı bir şekilde farklılaştığı görülmektedir ($F=5127,707$; $p < 0,001$). Söz konusu farklılığın hangi gruplar arasında olduğunu görmek amacıyla işlem sonrası (Post-Hoc) testlerinden Tamhane testi sonuçlarına bakılmıştır. Tamhane testi sonuçlarına göre G_YEYN ile G_DEYN ($md= 28,51$; $p < 0,001$) ve G_DEDN ($md=29,08$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur. G_YEDN ile G_DEYN ($md=30,02$; $p < 0,001$) ve G_DEDN ($md=30,59$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur. G_DEYN ile G_YEYN

($md = -28,51$; $p < 0,001$), G_YEDN ($md = -30,02$; $p < 0,001$) ve G_DEDN ($md = 0,57$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur. G_DEDN ile G_YEYN ($md = -29,08$; $p < 0,001$), G_YEDN ($md = -30,59$; $p < 0,001$) ve G_DEYN ($md = -0,57$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur.

Tablo 3.9’da grup değişkeni açısından dönem sonu ortalama puan faktörünün anlamlı bir şekilde farklılaştığı görülmektedir ($F = 13349,153$; $p < 0,001$). Söz konusu farklılığın hangi gruplar arasında olduğunu görmek amacıyla işlem sonrası (Post-Hoc) testlerinden Tamhane testi sonuçlarına bakılmıştır. Tamhane testi sonuçlarına göre G_YEYN ile G_YEDN ($md = 32,71$; $p < 0,001$) ve G_DEDN ($md = 40,32$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur. G_YEDN ile G_YEYN ($md = -32,71$; $p < 0,001$), G_DEYN ($md = -32,76$; $p < 0,001$) ve G_DEDN ($md = 7,60$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur. G_DEYN ile G_YEDN ($md = 32,76$; $p < 0,001$) ve G_DEDN ($md = 40,37$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur. G_DEDN ile G_YEYN ($md = -40,32$; $p < 0,001$), G_YEDN ($md = -7,60$; $p < 0,001$) ve G_DEYN ($md = -40,37$; $p < 0,001$) arasında anlamlı bir farklılık bulunmuştur.

Yapılan analizler sonucunda deney ve kontrol gruplarının istatistiksel olarak anlamlı bir şekilde benzer özellikler gösterdikleri, alt grupların ise birbirlerinden istatistiksel olarak anlamlı bir şekilde farklılaştıkları belirlenmiştir.

Deney ve kontrol gruplarındaki öğrenenler belirlendikten sonra bu veriler, veritabanına işlenmiştir. Bu işlemin ardından deney grubundaki öğrenenlere PDP, geri bildirim mesajları ve öğrenme malzemelerinin yer aldığı bir ders tasarımı sunulurken kontrol grubundaki öğrenenlere sadece öğrenme malzemeleri sunulmuştur.

3.4.3.3. *Öğrenme analitikleri tabanlı performans değerlendirme paneli kullanımının öğrenme sürecine etkilerinin belirlenmesi*

Kitlesel açık ve uzaktan öğrenme sistemlerinde PDP kullanımının öğrenme sürecine etkileri (Araştırma Sorusu 4), alt araştırma soruları bağlamında incelenmiştir. Alt araştırma soruları aşağıda verilmiştir:

- 4.1. Deney ve kontrol gruplarının ÖYS’de oturum açma sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
- 4.2. Deney ve kontrol gruplarının ÖYS’de oturum açtıkları gün sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
- 4.3. Deney ve kontrol gruplarının öğrenme malzemelerine erişim sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
- 4.4. Deney ve kontrol gruplarının akademik performanslarında istatistiksel olarak anlamlı bir farklılık var mıdır?

Deney ve kontrol grupları arasında oturum açma sayıları, oturum açtıkları gün sayıları, öğrenme malzemelerine erişim sayıları ve akademik performanslarında istatistiksel olarak anlamlı bir farklılık olup olmadığının belirlenmesi için bağımsız örneklem t-testi yapılmıştır. Bağımsız örneklem t-testi, iki bağımsız örneklemin ilgili değişken bağlamında ortalamaları arasında istatistiksel olarak anlamlı bir fark olup olmadığını belirlemek için kullanılan parametrik bir testtir (Gay vd., 2012).

3.4.3.4. *Öğrenme analitikleri tabanlı performans değerlendirme paneline yönelik öğrenen görüşlerinin belirlenmesi*


Kitlesel bir uzaktan eğitim uygulamasında sunulan öğrenme analitikleri tabanlı performans değerlendirme paneline (PDP) yönelik öğrenen görüşlerinin incelenmesi amacıyla deney grubundaki öğrenenlere çevrimiçi anket uygulanmıştır. Ankete katılım gönüllülük esasına dayanmaktadır. Anket 2 tane 3’lü likert tipi, 25 tane 5’li likert tipi ve 1 tane açık uçlu maddeden oluşmaktadır. Bu maddeler öğrenenlerin PDP kullanımları, mesaj okuma durumları ve PDP’ye yönelik görüşlerinden oluşmaktadır (EK-10).

4. BULGULAR VE YORUM

Bu bölümde, öğrenme malzemeleri kullanım örüntülerinin ve öğrenen profillerinin belirlenmesi, öğrenenlerin akademik performanslarına yönelik tahmin modelinin geliştirilmesi ve PDP'nin öğrenme sürecindeki etkilerinin incelenmesi süreçlerinde elde edilen bulgular sunulmaktadır.

4.1. Öğrenenlerin Öğrenme Malzemeleri Erişimlerinin İncelenmesi

Öğrenme malzemeleri erişim durumlarının incelenmesi için 2019-2020 öğretim yılı Güz dönemi 30 Eylül 2019-20 Ocak 2020 tarihleri arasında 602.372 öğrenene ait 7.115.874 oturum ve 48.990.340 etkinlik analiz edilmiştir. Şekil 4.1'de öğrenenlerin malzeme bazlı toplam ve ortalama erişimleri verilmiştir.




Şekil 4.1. Öğrenenlerin öğrenme malzemelerine toplam ve ortalama erişimleri


Şekil 4.1 incelendiğinde öğrenenlerin en çok eriştikleri malzemelerin ünite özeti ve çıkmış sınav soruları, en az eriştikleri malzemelerin ise eders ve infografik olduğu görülmektedir. Sistemde her malzeme eşit sayıda bulunmadığı için bu durum öğrenme malzemeleri erişim sayısını etkileyebilir. Bu nedenle toplam erişimlerin yanı sıra ortalama

erişimlerin de incelenmesi bulguların yorumlanması açısından katkı sağlayabilir. Ortalama erişimler açısından en yüksek erişimler deneme sınavı ve ünite özeti, en düşük erişimler ise infografik ve eders malzemelerinde gözlemlenmiştir. Toplam ve ortalama erişimler incelendiğinde benzer sonuçlar ortaya çıkmakla birlikte deneme sınavı erişimlerinde bir farklılık olduğu belirlenmiştir. Şekil 4.1 incelendiğinde öğrenenlerin çoğunlukla deneme sınavı, ünite özeti ve çıkmış sınav soruları malzemelerini kullanmayı tercih ettikleri söylenebilir. Şekil 4.2’de öğrenenlerin yaş gruplarına göre toplam ve ortalama malzeme erişimleri verilmiştir.

Yaş Gruplarına göre Toplam Erişim



Yaş Gruplarına göre Ortalama Erişim




Şekil 4.2. Öğrenenlerin yaş gruplarına göre öğrenme malzemelerine toplam ve ortalama erişimleri

Yaş gruplarına göre en yüksek toplam erişim 26-33 yaş grubunda, en yüksek ortalama erişim ise 42 yaş ve üstünde gözlenmiştir. En düşük toplam ve ortalama erişim ise 25 yaş ve altı grupta ortaya çıkmıştır. Şekil 4.2 incelendiğinde 18-33 yaş aralığında ünite özeti, 34 ve üstünde ise çıkmış sınav soruları toplam erişimi en yüksektir. Yaş yükseldikçe deneme sınavı erişiminde artış olduğu görülmektedir. Bu durum ortalama erişimler incelendiğinde daha da ön plana çıkmaktadır. Özellikle 42 yaş ve üstündeki öğrenenlerin deneme sınavı ortalama erişimleri diğer yaş gruplarına göre oldukça yüksektir. Yaş grupları bağlamında en az erişilen malzemeler, eders ve infografiktir.


Öğrenme malzemeleri erişimleri cinsiyetler açısından değerlendirildiğinde ise kadınların erkeklerden hem toplam erişim hem de ortalama erişimler açısından daha yüksek erişim değerlerine sahip oldukları belirlenmiştir.

Şekil 4.3'te öğrenenlerin genel not ortalamalarına göre malzeme erişim durumları verilmiştir.

Genel Not Ortalamalarına göre Toplam Erişim



Genel Not Ortalamalarına göre Ortalama Erişim




Şekil 4.3. Öğrenenlerin genel not ortalamalarına göre öğrenme malzemelerine toplam ve ortalama erişimleri

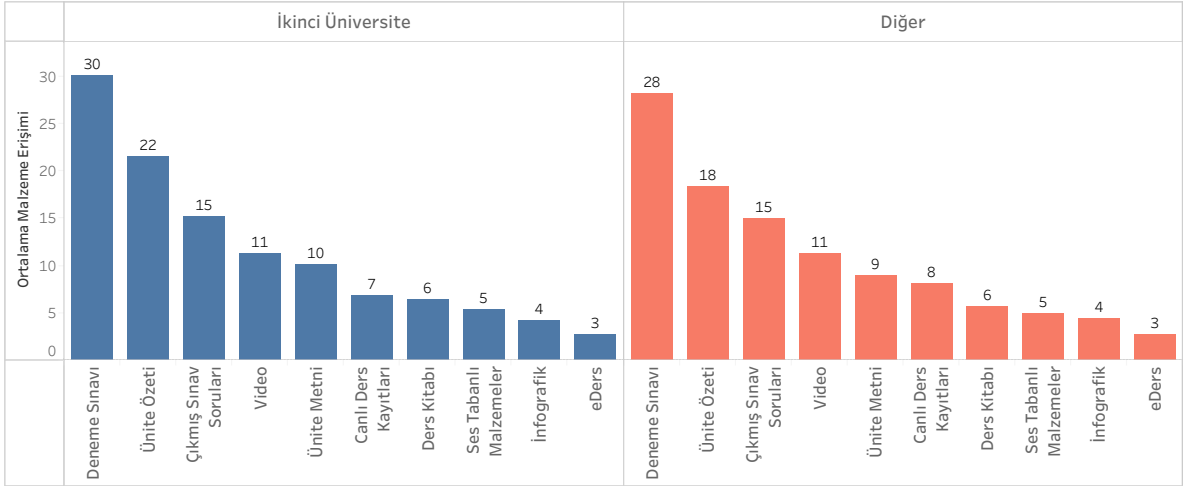
Öğrenme malzemeleri erişimi genel not ortalamaları bağlamında değerlendirildiğinde en yüksek toplam erişim 2,00-2,99; en yüksek ortalama erişim ise 3,00-4,00 not aralığında gözlenmiştir. En düşük erişimler ise 0,00-0,99 not aralığında ortaya çıkmıştır. Şekil 4.3 incelendiğinde deneme sınavı erişiminin not ortalamaları arttıkça yükseldiği görülmektedir. 0,00-0,99 not aralığında en yüksek ortalama erişim değeri ünite özetinde diğer grupların tamamında ise deneme sınavındadır. Özellikle 3,00-4,00 not aralığında deneme sınavı erişimi diğer grupların neredeyse 2 katıdır.

Şekil 4.4'te kayıt türlerine göre öğrenenlerin malzeme erişimleri verilmiştir.

Kayıt Türlerine göre Toplam Erişim




Kayıt Türlerine göre Ortalama Erişim



Şekil 4.4. Öğrenenlerin kayıt türlerine göre öğrenme malzemelerine toplam ve ortalama erişimleri

Kayıt türlerine göre malzeme erişimleri incelendiğinde İkinci Üniversite kapsamında kayıt yaptıran öğrenenlerin öğrenme malzemeleri toplam ve ortalama erişimlerinin diğer kayıt türlerindeki öğrenenlerden daha yüksek olduğu belirlenmiştir. Toplam erişim sayıları açısından en fazla erişim, İkinci Üniversitede ünite özetinde diğerlerinde ise çıkmış sınav sorularında ortaya çıkmıştır. Ortalama erişimler açısından her iki grupta da en yüksek erişimi olan malzeme deneme sınavıdır.

Şekil 4.5'te öğrenenlerin Güz dönemindeki aylar bağlamında erişimleri yer almaktadır.




Şekil 4.5. Öğrenenlerin aylara göre öğrenme malzemelerine toplam ve ortalama erişimleri


Öğrenme malzemelerine erişim aylar bağlamında incelendiğinde öğrenenlerin toplam malzeme erişimlerinin Aralık ayında en yüksek, Eylül ayında ise en düşük olduğu belirlenmiştir. Dönem 30 Eylül 2019'da başladığı için Eylül ayında öğrenenlerin sisteme eriştiği sadece 1 gün bulunmaktadır. Bu bağlamda değerlendirildiğinde en düşük toplam malzeme erişiminin Ekim ayında olduğu değerlendirilmektedir. Ortalama erişimler açısından ele alındığında Eylül ayından itibaren bir düşüş olduğu görülmektedir. Tarih bazlı değerlendirildiğinde en yüksek erişimler 13-14 Aralık 2019 ve 17 Ocak 2020, en düşük erişimler ise 28 Kasım 2019 ve 6 Ekim 2019'da gözlenmiştir. En yüksek erişimler ara sınav ve dönem sonu sınavı öncesinde ortaya çıkmıştır. Özellikle ara sınav öncesindeki hafta en yüksek erişim sayılarına erişilmiştir. Ortalama erişimler açısından ise 30 Eylül 2019 ve 1

Ekim 2019 tarihlerinde en yüksek erişimler görülmüştür. Bu tarihlerden sonra ortalama erişim düzeylerinde düşüşler yaşanmıştır. Ortalama erişimler açısından değerlendirildiğinde öğrenenlerin en yüksek ortalama erişimlerinin dönem başında olduğu görülmektedir. Şekil 4.6’da aylara göre erişim, öğrenme malzemeleri bazında sunulmaktadır.

Aylara göre Toplam Erişim



Aylara göre Ortalama Erişim




Şekil 4.6. Öğrenenlerin aylara göre öğrenme malzemeleri bazlı toplam ve ortalama erişimleri

Şekil 4.6 incelendiğinde Ekim ve Kasım aylarında ünite özetlerinin, sınav dönemleri olan Aralık ve Ocak aylarında ise çıkmış sınav soruları ve deneme sınavı erişimlerinin yüksek olduğu görülmektedir. Sınav dönemlerinde öğrenenlerin soru tabanlı malzemelere

yönelindikleri söylenebilir. Ortalama erişimler incelendiğinde ise Ekim ve Kasım aylarında ünite özeti, Aralık ve Ocak aylarında ise deneme sınavı erişimi en yüksektir.


Şekil 4.7’de hafta bazlı erişimleri yer almaktadır.



Şekil 4.7. Öğrenenlerin haftalara göre öğrenme malzemelerine toplam ve ortalama erişimleri

Şekil 4.7 incelendiğinde öğrenenlerin en yüksek malzeme erişimleri sırasıyla Hafta 11 ve Hafta 16’da gözlenmiştir. Bu haftalar, ara sınav ve dönem sonu sınavı haftalarıdır. Diğer haftalarda kullanımlar birbirine yakın olmakla birlikte sınava yakın haftalarda yükselme olduğu görülmektedir. Ortalama erişimlere bakıldığında ise Hafta 1 ve Hafta 2’de ortalama erişimlerin en yüksek olduğu görülmektedir. En düşük ortalama erişim ise ara sınav sonrası olan Hafta 12’de gözlemlenmiştir.


Şekil 4.8’de öğrenenlerin gün bazlı öğrenme malzemesi erişimleri sunulmaktadır.



Şekil 4.8. Öğrenenlerin günlere göre öğrenme malzemelerine toplam ve ortalama erişimleri

Şekil 4.8 incelendiğinde öğrenenlerin hem toplam hem de ortalama erişimlerinin en fazla Cuma ve Pazartesi günleri olduğu görülmektedir. En az erişim ise hafta sonu günlerinde gözlenmiştir. Pazartesi gününden itibaren erişimlerde düşüş olduğu belirlenmiştir.

Şekil 4.9’da öğrenenlerin gün ve saat bazlı erişimleri sunulmaktadır.



Şekil 4.9. Öğrenenlerin haftalara göre öğrenme malzemelerine toplam ve ortalama erişimleri

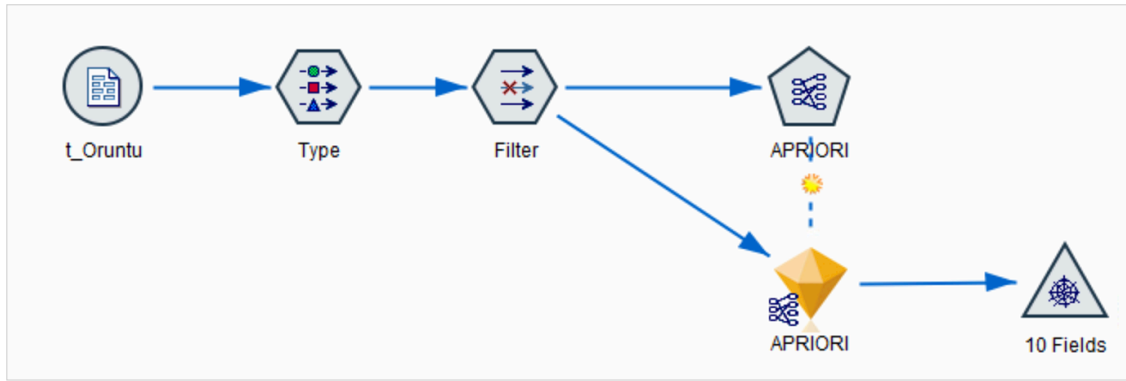
Öğrenenlerin öğrenme malzemelerine en fazla eriştikleri gün ve saatler sırasıyla; Pazartesi 14:00-14:59 ve 15:00-15:59, Cuma 16:00-16:59, Pazartesi 16:00-16:59 ve Cuma 15:00-15:59 olarak belirlenmiştir. En yoğun olarak katılım gösterilen saatler ise sırasıyla; 15:00-15:59, 14:00-14:59, 16:00-16:59 ve 13:00-13:59’dur. En az katılımın olduğu saatler 24:00-08:59 saatleri arası olarak bulunmuştur. Öğrenenlerin genel olarak öğleden sonra çalışma etkinliklerinin arttığı görülmektedir.

4.2. Çevrimiçi Öğrenme Ortamında Öğrenenlerin Davranış Örüntülerinin Belirlenmesi

Çevrimiçi öğrenme ortamında öğrenen davranış örüntülerinin belirlenmesi için 2019-2020 öğretim yılı Güz dönemi verileri ile çalışılmıştır. Bu kapsamda, 30 Eylül 2019-20 Ocak 2020 tarihleri arasındaki 602.372 öğrenene ait öğrenme malzemelerine erişimi içeren veriler analiz edilmiştir. Örüntüler; Apriori, CARMA ve FP-Growth algoritmaları kullanılarak elde edilmiştir. Bu bölümde davranış örüntülerinin belirlenmesine yönelik olarak algoritmalar bağlamında elde edilen bulgular ve yapılan değerlendirmeler yer almaktadır.

4.2.1. Apriori algoritması ile elde edilen davranış örüntüleri

Bu araştırma kapsamında Apriori algoritması, IBM SPSS Modeler üzerinde çalıştırılmıştır. Öncelikle t_Örüntü tablosundaki veriler tür ve filtre düğümleri ile düzenleme yapılarak Apriori algoritmasına uygun hale getirilmiş ve algoritma çalıştırılmıştır (Görsel 4.1).



Görsel 4.1. Apriori algoritması uygulama ekranı

Analizde minimum destek değeri %20, güven değeri ise %85 olarak girilmiştir. Bunun sonucunda 33 kural elde edilmiştir. Kuralların sonuçlarında çıkmış sınav soruları ve ünite özeti yer almıştır. Kurallar, güven değeri sıralı olarak Tablo 4.1’de verilmiştir.

Tablo 4.1. Apriori algoritması ile elde edilen birliktelik kuralları (Güven değeri sıralı)

Kural No	Öncüller	Sonuç	Destek Değeri (%)	Güven Değeri (%)	Lift Değeri
4	Deneme Sınavı, Ünite Metni	Çıkmış Sınav Soruları	21,99	94,32	1,20
5	Deneme Sınavı, Ünite Özeti	Çıkmış Sınav Soruları	25,29	93,94	1,19
22	Ses Tabanlı Malzemeler, Video, Ünite Özeti	Çıkmış Sınav Soruları	20,04	92,16	1,17
30	Video, Ünite Metni, Ünite Özeti	Çıkmış Sınav Soruları	23,73	92,00	1,17
26	Ses Tabanlı Malzemeler, Ünite Metni, Ünite Özeti	Çıkmış Sınav Soruları	21,86	92,00	1,17
21	Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları	Ünite Özeti	20,74	90,95	1,47
2	Deneme Sınavı	Çıkmış Sınav Soruları	32,39	90,92	1,15
28	Video, Ders Kitabı, Ünite Özeti	Çıkmış Sınav Soruları	21,49	90,90	1,15
27	Ses Tabanlı Malzemeler, Ünite Metni, Çıkmış Sınav Soruları	Ünite Özeti	22,14	90,82	1,47
24	Ses Tabanlı Malzemeler, Ders Kitabı, Ünite Özeti	Çıkmış Sınav Soruları	20,23	90,46	1,15
31	Video, Ünite Metni, Çıkmış Sınav Soruları	Ünite Özeti	24,17	90,34	1,46
14	Video, Ünite Metni	Çıkmış Sınav Soruları	26,80	90,17	1,14
3	Deneme Sınavı, Ünite Metni	Ünite Özeti	21,99	90,14	1,46
10	Ses Tabanlı Malzemeler, Ünite Metni	Çıkmış Sınav Soruları	24,63	89,91	1,14
11	Ses Tabanlı Malzemeler, Ünite Özeti	Çıkmış Sınav Soruları	27,83	89,76	1,14
15	Video, Ünite Özeti	Çıkmış Sınav Soruları	30,79	89,62	1,14
7	Ses Tabanlı Malzemeler, Video	Çıkmış Sınav Soruları	23,56	89,53	1,14
33	Ders Kitabı, Ünite Metni, Çıkmış Sınav Soruları	Ünite Özeti	29,25	89,45	1,45
32	Ders Kitabı, Ünite Metni, Ünite Özeti	Çıkmış Sınav Soruları	29,38	89,06	1,13
9	Ses Tabanlı Malzemeler, Ünite Metni	Ünite Özeti	24,63	88,76	1,44
13	Video, Ünite Metni	Ünite Özeti	26,80	88,55	1,43
1	Canlı Ders Kayıtları	Çıkmış Sınav Soruları	24,13	88,27	1,12
19	Ünite Metni, Ünite Özeti	Çıkmış Sınav Soruları	43,24	87,61	1,11
23	Ses Tabanlı Malzemeler, Video, Çıkmış Sınav Soruları	Ünite Özeti	21,09	87,56	1,42
12	Video, Ders Kitabı	Çıkmış Sınav Soruları	25,79	87,31	1,11
20	Ünite Metni, Çıkmış Sınav Soruları	Ünite Özeti	43,43	87,23	1,41
25	Ses Tabanlı Malzemeler, Ders Kitabı, Çıkmış Sınav Soruları	Ünite Özeti	21,09	86,80	1,41
29	Video, Ders Kitabı, Çıkmış Sınav Soruları	Ünite Özeti	22,52	86,75	1,41
16	Ders Kitabı, Ünite Metni	Ünite Özeti	33,98	86,48	1,40
18	Ders Kitabı, Ünite Özeti	Çıkmış Sınav Soruları	37,43	86,23	1,09
17	Ders Kitabı, Ünite Metni	Çıkmış Sınav Soruları	33,98	86,09	1,09
8	Ses Tabanlı Malzemeler, Ders Kitabı	Çıkmış Sınav Soruları	24,58	85,78	1,09
6	Ses Tabanlı Malzemeler, Video	Ünite Özeti	23,56	85,06	1,38

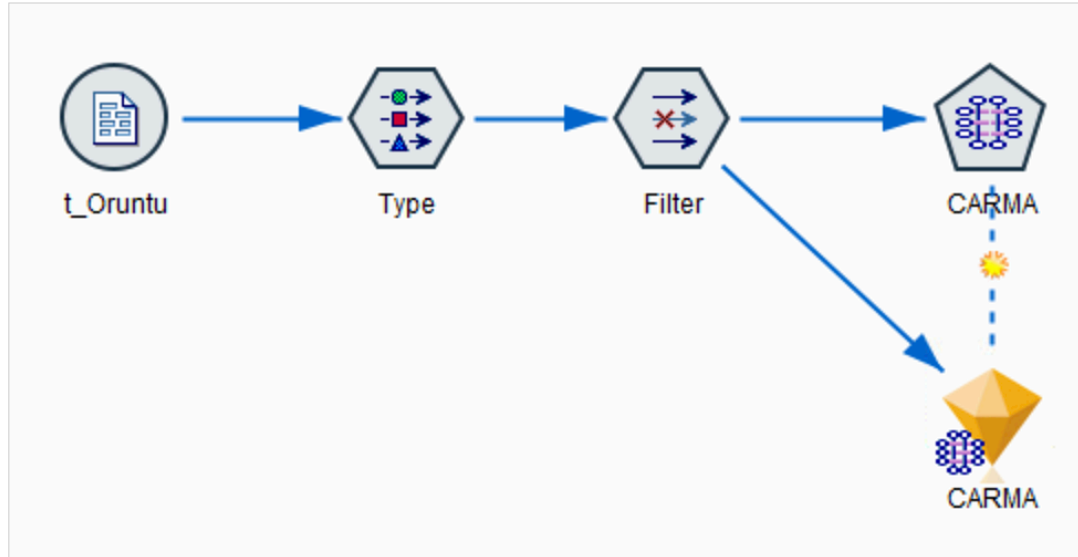
Tablo 4.1 incelendiğinde en yüksek güven değerine sahip kuralların 4, 5 ve 22 numaralı kurallar olduğu görülmektedir. Destek değerinin en yüksek olduğu kurallar ise 20, 19 ve 18 numaralı kurallardır. Lift değeri ise 21, 27 ve 31 numaralı kurallarda en yüksek değere sahiptir. En yüksek güven değerine sahip 10 kural aşağıdaki şekilde yorumlanmaktadır:

- **Kural 4:** Deneme sınavı, ünite metni ve çıkmış sınav soruları analiz edilen kullanımların %22'sinde birlikte kullanılmıştır. Deneme sınavı ve ünite metnini kullanan öğrenenlerin %94'ünün çıkmış sınav sorularını da kullandığı görülmüştür.
- **Kural 5:** Deneme sınavı, ünite özeti ve çıkmış sınav soruları analiz edilen kullanımların %25'inde birlikte kullanılmıştır. Deneme sınavı ve ünite özetini kullanan öğrenenlerin %94'ünün çıkmış sınav sorularını da kullandığı görülmüştür.
- **Kural 22:** Ses tabanlı malzemeler, video, ünite özeti ve çıkmış sınav soruları analiz edilen kullanımların %20'sinde birlikte kullanılmıştır. Ses tabanlı malzemeler, video ve ünite özetini kullanan öğrenenlerin %92'sinin çıkmış sınav sorularını da kullandığı görülmüştür.
- **Kural 30:** Video, ünite metni, ünite özeti ve çıkmış sınav soruları analiz edilen kullanımların %24'ünde birlikte kullanılmıştır. Video, ünite metni ve ünite özetini kullanan öğrenenlerin %92'sinin çıkmış sınav sorularını da kullandığı görülmüştür.
- **Kural 26:** Ses tabanlı malzemeler, ünite metni, ünite özeti ve çıkmış sınav soruları analiz edilen kullanımların %22'sinde birlikte kullanılmıştır. Ses tabanlı malzemeler, ünite metni ve ünite özetini kullanan öğrenenlerin %92'sinin çıkmış sınav sorularını da kullandığı görülmüştür.
- **Kural 21:** Deneme sınavı, ünite metni, çıkmış sınav soruları ve ünite özeti analiz edilen kullanımların %21'inde birlikte kullanılmıştır. Deneme sınavı, ünite metni ve çıkmış sınav sorularını kullanan öğrenenlerin %91'inin ünite özetini de kullandığı görülmüştür.
- **Kural 2:** Deneme sınavı ve çıkmış sınav soruları analiz edilen kullanımların %32'sinde birlikte kullanılmıştır. Deneme sınavını kullanan öğrenenlerin %91'inin çıkmış sınav sorularını da kullandığı görülmüştür.

- **Kural 28:** Video, ders kitabı, ünite özeti ve çıkmış sınav soruları analiz edilen kullanımların %22'sinde birlikte kullanılmıştır. Video, ders kitabı ve ünite özeti kullanan öğrenenlerin %91'inin çıkmış sınav sorularını da kullandığı görülmüştür.
- **Kural 27:** Ses tabanlı malzemeler, ünite metni, çıkmış sınav soruları ve ünite özeti analiz edilen kullanımların %22'sinde birlikte kullanılmıştır. Ses tabanlı malzemeler, ünite metni ve çıkmış sınav sorularını kullanan öğrenenlerin %91'inin ünite özeti de kullandığı görülmüştür.
- **Kural 24:** Ses tabanlı malzemeler, ders kitabı, ünite özeti ve çıkmış sınav soruları analiz edilen kullanımların %20'sinde birlikte kullanılmıştır. Ses tabanlı malzemeler, ders kitabı ve ünite özeti kullanan öğrenenlerin %91'inin çıkmış sınav sorularını da kullandığı görülmüştür.

4.2.2. CARMA algoritması ile elde edilen davranış örüntüleri

Bu araştırmada CARMA algoritması, IBM SPSS Modeler üzerinde çalıştırılmıştır. Öncelikle t_Örüntü tablosundaki veriler, tür ve filtre düğümleri ile düzenlemeler yapılarak CARMA algoritmasına uygun hale getirilmiş ve algoritma çalıştırılmıştır (Görsel 4.2).




Görsel 4.2. CARMA algoritması uygulama ekranı

Analizde minimum destek değeri %20, güven değeri ise %85 olarak girilmiştir. Bunun sonucunda 25 kural elde edilmiştir (EK-1). Kuralların sonuçlarında çıkmış sınav soruları ve ünite özeti yer almıştır. Apriori algoritmasından farklı olarak 3, 21, 22, 23, 24, 25, 28 ve 29 numaralı kurallar CARMA algoritması sonuçlarında yer almamaktadır. Diğer kurallar ise güven ve destek değerlerinde farklılıklar olmakla birlikte benzer şekilde bulunmuştur.

4.2.3. FP-Growth Algoritması ile elde edilen davranış örüntüleri

Bu araştırmada FP-Growth algoritması, RapidMiner Studio üzerinde çalıştırılmıştır. Burada öncelikle t_Örüntü tablosunda öğrenme malzemelerinin pozitif ve negatif değerleri düzenlenmiştir. Analize öğrenenlerin öğrenme malzemeleri kullanım durumunu gösteren 10 alan girmiştir. Daha sonra sürece FP-Growth algoritma operatörü eklenmiştir. Minimum destek değeri %95 olarak girilmiş ve süreç çalıştırılmıştır. Bu işlemin ardından 51 adet en sık tekrar eden nesne kümesi elde edilmiştir. Son olarak, birliktelik kuralları oluşturma operatörü eklenmiştir. Bu aşamada minimum güven değeri %85 olarak girilmiş ve süreç yeniden çalıştırılmıştır. Gerçekleştirilen bu adımlar, Görsel 4.3'te sunulmuştur.




Görsel 4.3. FP-Growth algoritması uygulama ekranı

Yapılan analiz sonucunda minimum destek değeri %20 ve minimum güven değeri %85 olan 25 birliktelik kuralı elde edilmiştir (EK-2). FP-Growth ile elde edilen kurallar, CARMA algoritması ile elde edilen kurallarla aynıdır. Bunun yanı sıra, Apriori algoritması sonucunda elde edilen 3, 21, 22, 23, 24, 25, 28 ve 29 numaralı kurallar, FP-Growth algoritması sonuçlarında yer almamaktadır. Diğer kurallar ise güven ve destek değerlerinde farklılıklar olmakla birlikte benzer şekilde bulunmuştur.

4.2.4. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntü modellerinin değerlendirilmesi

Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi için Apriori, CARMA ve FP-Growth algoritmaları kullanılmıştır. Bu algoritmalar ile geliştirilen modellerdeki birliktelik kuralları benzer olmakla birlikte aynı güven ve destek değerlerinde Apriori'nin diğer algoritmalara göre daha fazla kural oluşturduğu görülmüştür. CARMA ve FP-Growth algoritmaları ile aynı kurallar elde edilmiştir. Bu farklılığın algoritmaların kural çıkarma süreçlerinin farklı olmasından kaynaklandığı söylenebilir. Elde edilen kurallar diğer algoritmalarındaki sonuçları da içerdiği için bu bölümdeki yorumlar, Apriori algoritması ile elde edilen kurallar üzerinden yapılmıştır. Öğrenme malzemeleri arasındaki ilişkiler, Şekil 4.10'da gösterilmektedir.



Şekil 4.10. Öğrenme malzemeleri arasındaki ilişkiler

Şekil 4.10 incelendiğinde ünite özeti, ünite metni, çıkmış sınav soruları, ders kitabı ve video malzemeleri arasındaki bağlantıların diğerlerinden daha güçlü olduğu görülmektedir. Bu durum, öğrenenlerin çalışmalarında bu öğrenme malzemelerini birlikte kullanma eğiliminde olduğunu göstermektedir.

Apriori algoritması ile elde edilen kuralların sonuç alanında çıkmış sınav soruları ve ünite özetleri bulunmaktadır. Destek değeri en yüksek olan kurallar sırasıyla; Kural 20 (Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti), Kural 19 (Ünite Metni, Ünite Özeti ⇒ Çıkmış Sınav Soruları) ve Kural 18'dir (Ders Kitabı, Ünite Özeti ⇒ Çıkmış Sınav Soruları). Bu kurallar, tüm kullanımlar içerisinde en çok tekrarlanan kurallardır. Güven değeri en yüksek olan kuralların ise sırasıyla; Kural 4 (Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları), Kural 5 (Deneme Sınavı, Ünite Özeti ⇒ Çıkmış Sınav Soruları) ve Kural 22 (Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları) olduğu belirlenmiştir.

Güven ve destek değerleri yüksek olan kurallar güçlü kurallar olarak değerlendirilmektedir; ancak bu kurallar her zaman ilginç olmayabilir (Han vd., 2012). Dahası örüntüleri sadece bu iki değere göre değerlendirmek yanıltıcı sonuçlara da neden olabilir. Destek-güven çerçevesini güçlendirmek için bir korelasyon ölçüm değeri olan lift değeri kullanılabilir (Han vd., 2012). Lift değeri, kuralın öneminin bir ölçüsüdür (IBM, 2014). Bu değer 1'den büyük olması, öncüller ve sonuçların beklenenden daha sık birlikte görüldüğünü göstermektedir (IBM, 2014). Bu durum, öncüller ve sonuçların pozitif korelasyona sahip olduğunu yani birinin ortaya çıkmasının diğerinin ortaya çıkmasını olumlu yönde etkilediğini ifade etmektedir (Han vd., 2012). Tablo 4.1 incelendiğinde elde edilen tüm kuralların lift değerlerinin 1'den yüksek olduğu görülmektedir. Lift değeri en yüksek olan kurallar ise sırasıyla; Kural 21 (Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti), Kural 27 (Ses Tabanlı Malzemeler, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti) ve Kural 31 (Video, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti) olarak belirlenmiştir. Güven ve destek değerlerine göre yapılan sıralamalardan farklı olarak lift değerine göre yapılan sıralamada en yüksek 3 değere ait kuralın sonuç alanında Ünite Özeti yer almaktadır.

Birliktelik kuralları öğrenenlerin genel not ortalaması bağlamında değerlendirildiğinde öğrenenlerin yüzdesel oranının en yüksek olduğu kurallar sırasıyla, Kural 21 (Deneme

Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti) ve Kural 23 (Ses Tabanlı Malzemeler, Video, Çıkmış Sınav Soruları ⇒ Ünite Özeti) olarak bulunmuştur. Bunun yanı sıra bu oranların notlarla beraber yükseldiği belirlenmiştir. Yaş grupları açısından incelendiğinde de tüm yaş gruplarında Kural 21 (Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti) daha fazla görülmektedir.

Öğrenenlerin oturum açtıkları ilk hafta bağlamında birliktelik kuralları ara sınav öncesi, ara sınav dönemi ve ara sınav sonrası olarak incelenebilir:

- Ara Sınav Öncesi: Dönem başlangıcından ara sınav dönemine kadar olan zaman diliminde genellikle Kural 21 (Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti), Kural 19 (Ünite Metni, Ünite Özeti ⇒ Çıkmış Sınav Soruları), Kural 23 (Ses Tabanlı Malzemeler, Video, Çıkmış Sınav Soruları ⇒ Ünite Özeti) ve Kural 32'nin (Ders Kitabı, Ünite Metni, Ünite Özeti ⇒ Çıkmış Sınav Soruları) daha fazla görüldüğü söylenebilir. Sınav haftasına yaklaşılmaya Kural 2 (Deneme Sınavı ⇒ Çıkmış Sınav Soruları) ön plana çıkmaya başlamıştır. Öğrenenlerin bu dönemde farklı öğrenme malzeme türlerini birlikte kullandıkları belirtilebilir. Bu kural gruplarındaki öğrenenlerin ünite özeti kullanımına yönlendirilmeleri olumlu bir etki yaratabilir.
- Ara Sınav Dönemi: Bu dönem ara sınav öncesindeki haftayı kapsamaktadır. Bu haftada en fazla görülen kurallar sırasıyla; Kural 2 (Deneme Sınavı ⇒ Çıkmış Sınav Soruları), Kural 21 (Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti) ve Kural 19 (Ünite Metni, Ünite Özeti ⇒ Çıkmış Sınav Soruları) olarak belirlenmiştir. İlgili haftada özellikle Kural 2'de büyük bir yükseliş görülmüştür. Ara sınav döneminde deneme sınavı, ünite özeti, ünite metni ve çıkmış sınav soruları kullanımına yönelim olduğu belirtilebilir.
- Ara Sınav Sonrası: Bu dönemde, ara sınav dönemine benzer örüntüler görülmüştür. Bunlardan farklı olarak ara sınav sonrasında Kural 1'in (Canlı Ders Kayıtları ⇒ Çıkmış Sınav Soruları) oranında diğer haftalara göre bir yükseliş olduğu görülmektedir.

Öğrenenlerin oturum açtıkları gün sayısı bağlamında birliktelik kuralları incelendiğinde oturum açtığı gün sayısı 3'ten az olan öğrenenlerin gösterdikleri davranış

örüntülerinin diğerlerinden farklı olduğu belirlenmiştir. Diğer gruplarda Kural 23 (Ses Tabanlı Malzemeler, Video, Çıkmış Sınav Soruları ⇒ Ünite Özeti) ve Kural 21 (Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti) daha yoğun olarak görülürken, oturum açtığı gün sayısı 3'ten az olan öğrenenlerde Kural 19 (Ünite Metni, Ünite Özeti ⇒ Çıkmış Sınav Soruları), Kural 2 (Deneme Sınavı ⇒ Çıkmış Sınav Soruları) ve Kural 1 (Canlı Ders Kayıtları ⇒ Çıkmış Sınav Soruları) daha yüksek oranda gözlenmiştir. Bu durum, öğrenenlerin günlük ortalama oturum açma sayıları açısından değerlendirildiğinde de sonuçlar benzer şekilde görüntülenmiştir. Öğrenenlerin oturum açma sayıları göz önüne alındığında da benzer bir durum olmakla birlikte oturum açma sayısı 15'ten yüksek olan öğrenenlerin diğerlerinden daha yüksek oranda Kural 4 (Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları) örüntüsünü gösterdikleri belirlenmiştir. Bu öğrenenlerin çoğunlukla deneme sınavı ve ünite metnini birlikte kullanmayı tercih ettikleri söylenebilir. Öğrenenlerin toplam faaliyet sayıları açısından da benzer bir yapı gözlenmekle birlikte en düşük seviyede kullanım gösteren öğrenenlerin diğer gruplardan farklı bir örüntü gösterdikleri belirlenmiştir. Bu öğrenenler, genellikle canlı ders kayıtları ve deneme sınavlarını kullanmışlardır.

4.3. Çevrimiçi Öğrenme Ortamında Öğrenen Profillerinin Belirlenmesi

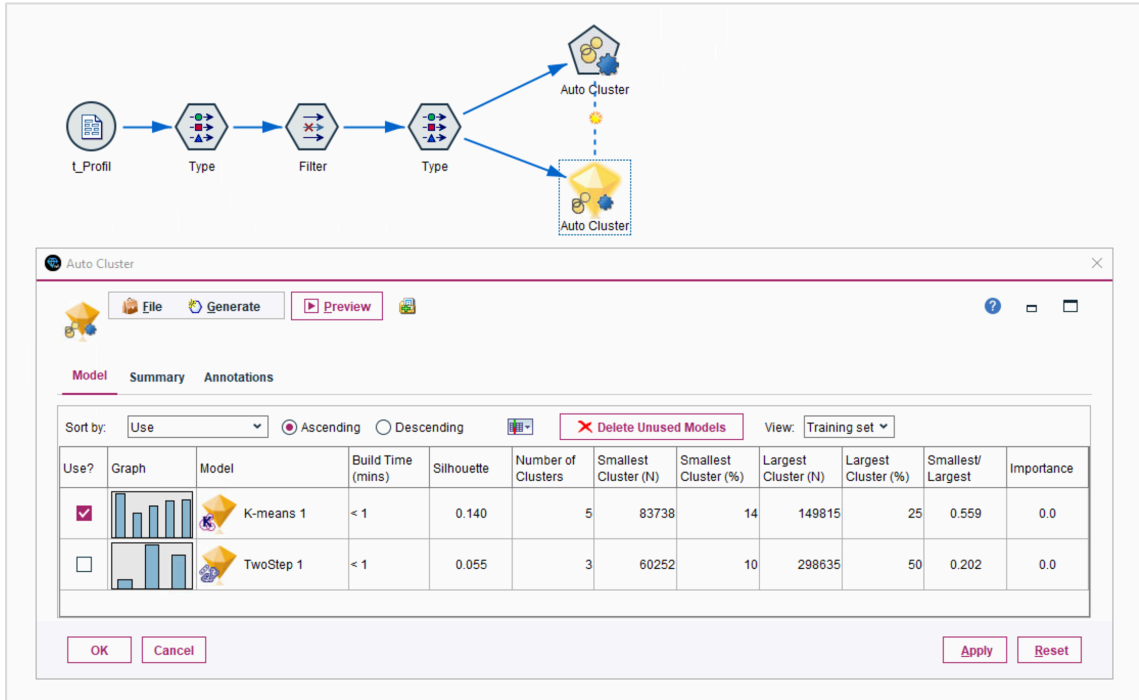
Öğrenen profillerinin belirlenmesi için 2019-2020 öğretim yılı Güz dönemi verileri ile çalışılmıştır. 30 Eylül 2019-20 Ocak 2020 tarihleri arasındaki faaliyetleri içeren 597.164 öğrenene ait veriler analiz edilmiştir. Öğrenen profillerinin belirlenmesinde kümeleme analizi algoritmaları kullanılmıştır. Analizlerde öncelikle özniteliklerin özellikleri ve aralarındaki ilişkiler belirlenmiş, sonrasında öznitelik seçimi yapılmıştır. Daha sonra IBM SPSS Modeler yazılımında yer alan ve otomatik kümeleme sonuçlarını veren düğüm kullanılarak analizler gerçekleştirilmiştir. Buradan elde edilen sonuçların iyileştirilmesi için tekrarlı deneysel çalışmalar yapılarak modeller geliştirilmiştir. Bu bölümde, algoritmalar bağlamında elde edilen bulgular sunulmaktadır.

4.3.1. TwoStep Algoritması ile elde edilen öğrenen profilleri

IBM SPSS Modeler yazılımında öncelikle 29 öznitelik girdi olarak işaretlenmiş ve otomatik kümeleme yapılmıştır. Girdi olarak işaretlenen özniteliklerin 19 tanesi sayısal, 10 tanesi ise kategorik veri türündedir. Bu öznitelikler Görsel 4.4'te, otomatik kümeleme analizi işlem adımları ve sonuçları ise Görsel 4.5'te verilmiştir.

Field	Measurement	Values	Missing	Check	Role
Öğrenci No	Continuous	[134108.0,9...		None	Record ID
Kullanılan Malzeme Sayısı	Continuous	[0.0,1.0]		None	Input
Toplam Faaliyet Suresi (dk)	Continuous	[0.0,1.0]		None	Input
Ara Sınav Puanı	Continuous	[0.0,1.0]		None	Input
Dönem Sonu Sınav Puanı	Continuous	[0.0,1.0]		None	Input
Sınava Girme Oranı	Continuous	[0.0,1.0]		None	Input
Oturum Sayısı	Continuous	[0.0,1.0]		None	Input
Oturum Açılan Gün Sayısı	Continuous	[0.0,1.0]		None	Input
Günlük Ortalama Oturma Açma Sayısı	Continuous	[0.0,1.0]		None	Input
Toplam Faaliyet Sayısı	Continuous	[0.0,1.0]		None	Input
Çıkmış Sınav Soruları	Continuous	[0.0,1.0]		None	Input
Ders Kitabı	Continuous	[0.0,1.0]		None	Input
Canlı Ders Kayıtları	Continuous	[0.0,1.0]		None	Input
Ünite Metni	Continuous	[0.0,1.0]		None	Input
Ünite Özeti	Continuous	[0.0,1.0]		None	Input
Video	Continuous	[0.0,1.0]		None	Input
Ses Tabanlı Malzeme	Continuous	[0.0,1.0]		None	Input
Deneme Sınavı	Continuous	[0.0,1.0]		None	Input
Dönem Sonu Ortalama Puan	Continuous	[0.0,1.0]		None	Input
Yaş	Continuous	[0.0,1.0]		None	Input
İlk Oturma Ayı	Nominal	1,9,10,11,12		None	Input
Apriori Kuralları	Nominal	CDK_CS,D...		None	Input
Cinsiyet	Flag	Kadın/Erkek		None	Input
Bölüm	Nominal	"ACL DURU...		None	Input
İlk Oturma Haftası	Nominal	1,2,3,4,40,4...		None	Input
Kayıt Türü	Flag	"ikinci niver...		None	Input
Meslek	Nominal	alıyor,alis...		None	Input
Yaş Grubu	Nominal	"25 ve alti", "...		None	Input
20_85_id	Nominal	"1","10","11"...		None	Input
15_75_id	Nominal	"Ders Kitab"...		None	Input

Görsel 4.4. Kümeleme analizi öznitelik tablosu

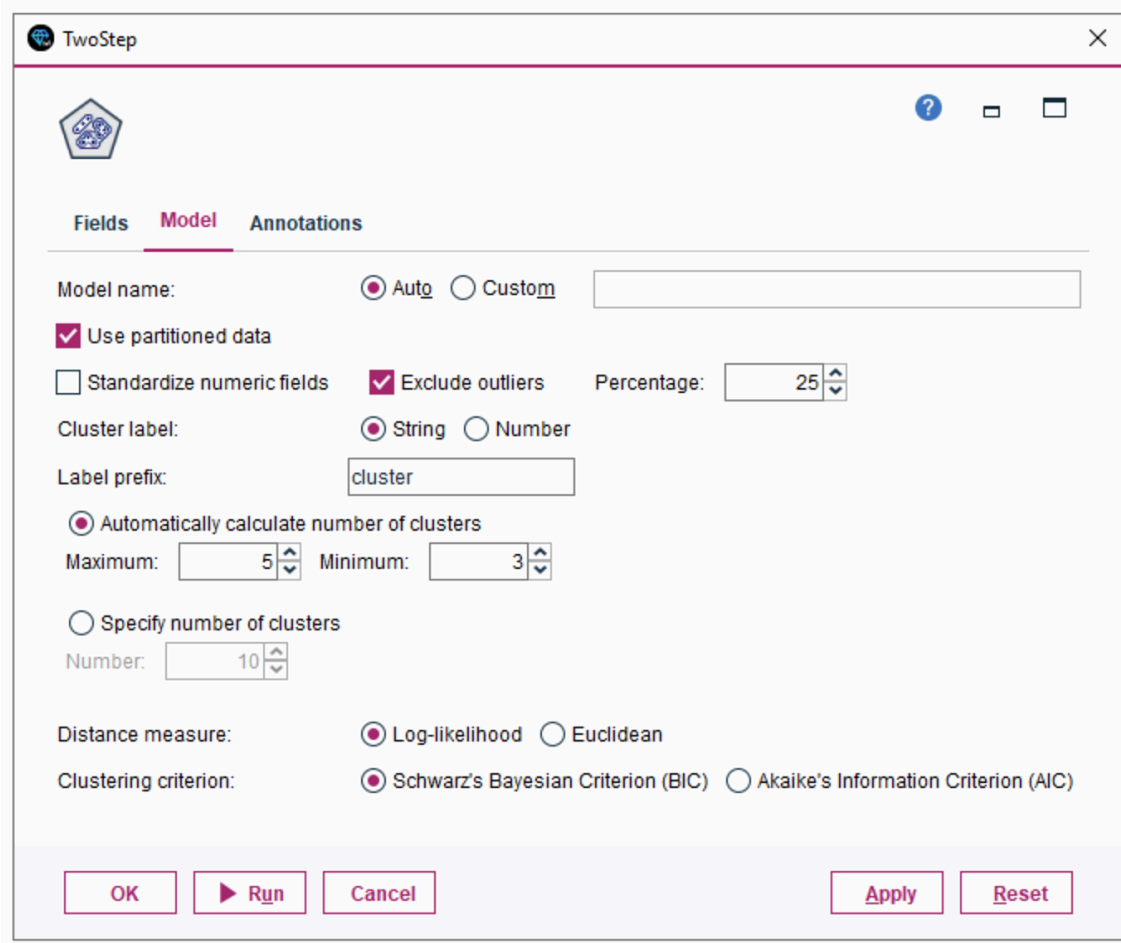


Görsel 4.5. Otomatik kümeleme sonuçları

Otomatik kümelemede K-means ve TwoStep algoritmaları ile analizler yapılmıştır. Küme kalitesi, Silhouette değeri ile incelenmektedir. Bu değer 1'e yaklaştıkça küme kalitesinin yükseldiği değerlendirilmektedir. Elde edilen değerler incelendiğinde her iki algoritma ile elde edilen Silhouette değerlerinin 0'a yakın olduğu görülmektedir. IBM SPSS Modeller'da k-means algoritması sadece sayısal verilerle çalışabilirken TwoStep algoritması kategorik ve sayısal veri türleri ile çalışabilmektedir. Bu nedenle profillerin belirlenmesine TwoStep algoritmasında yapılan deneysel denemeler ile devam edilmiştir.

TwoStep algoritması ile analizler yapılırken 3 farklı yol izlenmiştir. İlk aşamada öznitelik mühendisliği ile elde edilen girdiler kullanılmıştır. Daha sonra öznitelik sayısı çoktan aza olacak şekilde hazırlanan farklı öznitelik setleri ile analizler yapılmış ve son olarak öznitelik sayısı azdan çoğa olacak şekilde modeller çalıştırılmıştır. TwoStep algoritması ile analiz yapılırken %25 oranında aykırı değerler veri setinden çıkarılmıştır. Küme sayısı minimum 3, maksimum 5 olacak şekilde düzenlenmiştir. Uzaklık ölçüsü olarak hem kategorik hem de sayısal verilerle çalışabildiği için "Log-likelihood" seçilmiştir. Bu

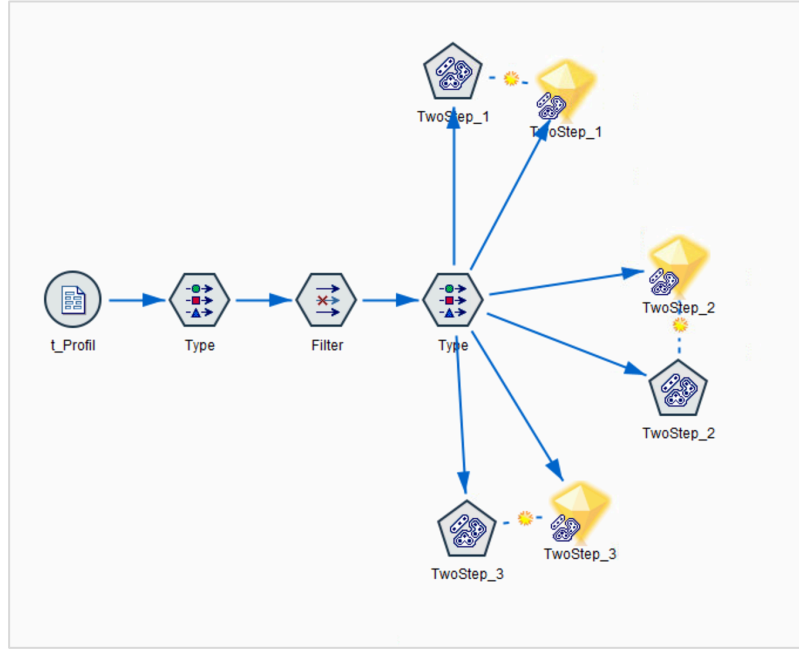
analizde kümeleme kriteri, “Schwarz’s Bayesian Criterion” olarak belirlenmiştir. TwoStep düğümü ekranı, Görsel 4.6’da verilmiştir.



The image shows the TwoStep software interface, specifically the Model configuration window. The window has a title bar with the TwoStep logo and a close button. Below the title bar is a navigation bar with three tabs: Fields, Model (selected), and Annotations. The Model tab is active, showing various configuration options. The Model name is set to 'Auto'. The 'Use partitioned data' checkbox is checked. The 'Standardize numeric fields' checkbox is unchecked, while the 'Exclude outliers' checkbox is checked, with a 'Percentage' of 25. The 'Cluster label' is set to 'String'. The 'Label prefix' is 'cluster'. The 'Automatically calculate number of clusters' radio button is selected, with a 'Maximum' of 5 and a 'Minimum' of 3. The 'Specify number of clusters' radio button is unselected, with a 'Number' of 10. The 'Distance measure' is set to 'Log-likelihood'. The 'Clustering criterion' is set to 'Schwarz's Bayesian Criterion (BIC)'. At the bottom of the window are buttons for 'OK', 'Run', 'Cancel', 'Apply', and 'Reset'.


Görsel 4.6. TwoStep düğüm ekranı

Öznetelik mühendisliği ile elde edilen öznetelikler kullanıldığında 4 küme elde edilmiş ve kümeleme kalitesi 0,2 olarak bulunmuştur. 0,2'nin altındaki değerler zayıf kümeleme kalitesini göstermektedir. Bu süreçte yapılan deneysel çalışmalar, Görsel 4.7’de gösterilmiştir.



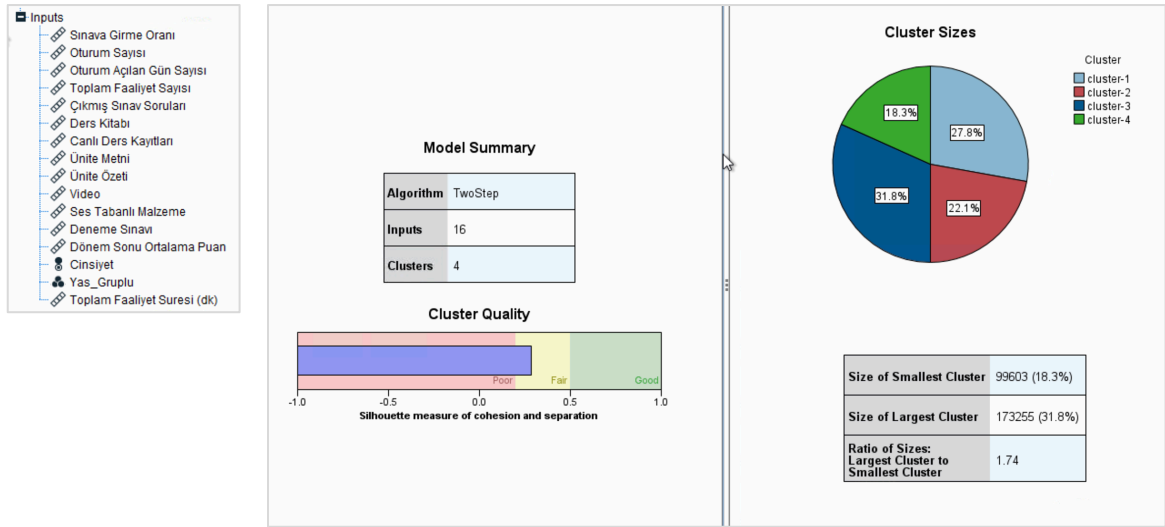
Görsel 4.7. *TwoStep analizleri-I*

İkinci aşamada çok sayıda öznitelikten az sayıda özneliğe doğru farklı veri setleri oluşturulmuş ve denemeler yapılmıştır. İlk analiz 29 girdi ile gerçekleştirilmiştir. Yapılan analiz sonucunda 3 küme elde edilmiş ve kümeleme kalitesi 0,1 olarak hesaplanmıştır. Özniteliklerin önem değerleri incelendiğinde, Kayıt Türü özneliğinin kümeleme analizi için önem değerinin düşük olduğu belirlenmiştir. Bu öznitelik çıkarılarak analiz yeniden gerçekleştirilmiştir. Bu işlemde sonra önem dereceleri düşük çıkan öznitelikler analizden çıkarılmaya devam edilmiştir. Analizden çıkarılan öznitelikler sırasıyla Meslek, 15_75_id (Birliktelik Kuralı numarası, Destek: %15, Güven: %75), 20_85_id (Birliktelik Kuralı numarası, Destek: %20, Güven: %85), Apriori Kuralları, Ara Sınav Puanı, Günlük Ortalama Oturum Açma Sayısı, İlk Oturum Ayı, İlk Oturum Haftası, Kullanılan Malzeme Türü Sayısı olmuştur. Bu öznitelikler çıkarıldıktan sonra kümeleme kalitesi 0,2'ye yükselmiştir. Yaş özneliği çıkarıldığında ise bu değer 0,3'e yükselmiştir. Bu süreçte yapılan analizler, Görsel 4.8'de gösterilmiştir.




Görsel 4.8. TwoStep analizleri-II

Analizlerin ikinci aşamasında 13 farklı model oluşturulmuştur. Elde edilen en yüksek kümeleme kalitesine sahip model sonuçları ve analizde kullanılan öz nitelikler, Görsel 4.9’da verilmiştir. Bu analizde 16 girdi ile 4 küme oluşturulmuş ve kümeleme kalitesi 0,2 olarak elde edilmiştir.



Görsel 4.9. TwoStep analizleri-II sonucu


Son olarak, az sayıdaki öznitelikten çok sayıdaki özniteliğe doğru denemeler yapılmıştır. İlk aşamada sadece öğrenme malzemeleri kullanımları ve yaş grubu öznitelikleri analize dahil edilmiştir. Canlı ders kayıtları erişim sayısı, çıkmış sınav soruları erişim sayısı, deneme sınavı erişim sayısı, ders kitabı erişim sayısı, ünite metni erişim sayısı, ünite özeti erişim sayısı, video erişim sayısı, ses tabanlı malzemeler erişim sayısı ve yaş grubu öznitelikleri girdi olarak analize dahil edilmiştir. Bu analiz sonucunda 4 küme elde edilmiş ve kümeleme kalitesi 0,9 olarak bulunmuştur. Ancak oluşan kümeler incelendiğinde kümelerin ayrılmalarının büyük oranda yaş özniteliğinden dolayı olduğu görülmüştür. Daha sonra Sınava Girme Oranı girdi olarak eklenmiş ve analiz yeniden çalıştırılmıştır. Bu işlem sonucunda 4 küme elde edilmiş ve kümeleme kalitesi 0,5 olarak hesaplanmıştır. Toplam Faaliyet Süresi (dk) ve Dönem Sonu Ortalama Puan girdileri eklenerek analiz çalıştırıldığında ise kümeleme kalitesi 0,4'e düşmüştür. Bu süreçte yapılan analizler, Görsel 4.10'da gösterilmiştir.



Görsel 4.10. *TwoStep analizleri-III*

Yapılan analizler sonucunda 12 girdi ile 7 küme elde edilen ve 0,5 küme kalitesine sahip analiz sonuçlarının diğerlerine göre ilgili değişkenler açısından daha ayırıcı olduğu belirlenmiştir. Bu nedenle elde edilen bu analiz, TwoStep algoritması ile elde edilen sonuç

olarak değerlendirilmiş ve bu kümelerin özellikleri açıklanmıştır. Bu analizde kullanılan girdiler ve analiz sonuçları, Görsel 4.11’de verilmiştir.



Görsel 4.11. *TwoStep analizi-III sonucu*

12 girdi ile yapılan bu analiz sonucunda 7 küme elde edilmiştir. En fazla öğrenen sayısına sahip olan küme, 6 numaralı kümedir. Bu kümede öğrenenlerin %29,6’sı yer almaktadır. Bunu Küme 4 (%19,4), Küme 2 (%18,7), Küme 1 (%17,5), Küme 7 (%7,3), Küme 5 (%4,1) ve Küme 3 (%3,4) izlemektedir. Küme karşılaştırma raporu incelendiğinde kümelerin dönem sonu ortalama puan, oturum açılan gün sayısı, yaş, sınava girme oranı ve oturum sayısı özneliklerinde daha çok farklılaştığı görülmüştür. Malzeme kullanımlarındaki farklılaşmanın ise düşük düzeyde olduğu gözlenmiştir. En küçük boyuta sahip olan Küme 3, Küme 5 ve Küme 7’nin öğrenme malzemelerine erişim ve akademik başarı puanları açısından birbirlerine oldukça benzer özellikte oldukları görülmüştür. Bu nedenle yorumlar yapılırken bu üç küme bir araya getirilerek değerlendirilmiştir. Bunun ardından dönem sonu ortalama puanı 0 olan öğrenenler filtrelendiğinde öğrenenlerin dönem sonu ortalama puanı 40,48, ortalama malzeme erişimi 53,15 olarak hesaplanmıştır.

Dönem sonu ortalama puan ve ortalama malzeme erişim değerleri göz önüne alınarak kümeler aşağıdaki şekilde isimlendirilmiştir:

- Küme 1, en yüksek öğrenme malzemeleri erişimine sahiptir. Ortalama dönem sonu puanı, genel ortalamanın üstündedir. Bu küme, “Yüksek Erişim Grubu” olarak isimlendirilmiştir.
- Küme 2, en yüksek dönem sonu ortalamasına sahip gruptur. Öğrenme malzemeleri erişimi de ortalamanın üstündedir. Bu küme, “Yüksek Puan Grubu” olarak isimlendirilmiştir.
- Küme 4’ün dönem sonu ortalama puanı ve malzeme erişimi ortalamanın altındadır. Bu küme, “Ortalama Altı Puan Grubu” olarak isimlendirilmiştir.
- Küme 6’nın dönem sonu ortalama puanı ortalamanın üstünde, malzeme erişimi ise ortalamanın altındadır. Bu küme, “Ortalama Üstü Puan Grubu” olarak isimlendirilmiştir.
- Küme 3, Küme 5 ve Küme 7 en düşük dönem sonu ortalama puan ve en düşük öğrenme malzeme erişiminin olduğu gruptur. Bu küme, “Düşük Puan Grubu” olarak isimlendirilmiştir.

Yüksek Erişim grubunda, 104.338 öğrenen bulunmaktadır. Öğrenenlerin %17’si bu kümede yer almaktadır. Bu öğrenenlerin tamamı, 42 yaş ve üstündedir. Öğrenenlerin %54’ü erkek, %46’sı kadındır. Öğrenenlerin %81’i çalışmaktadır. Bu gruptaki öğrenenlerin %53’ü ikinci üniversite kapsamında kayıtlıdır. Bu gruptaki öğrenenlerin dönem sonu ortalama puanları, 42’dir. Bu gruptaki öğrenenlerin sınava girme oranı Düşük Puan grubundan yüksek diğerlerinden ise düşük seviyededir. Öğrenenler, dönem boyunca ortalama 11 gün ve 18 defa oturum açmışlardır. Öğrenenlerin %56’sı ilk oturumlarını Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 2. ve 3. haftalar olarak belirlenmiştir. Bu haftalar, ekle-sil haftalarıdır. Bu gruptaki öğrenenlerin kaydolduktan hemen sonra sisteme giriş yaptıkları söylenebilir. Öğrenenler, ortalama 74 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 20 saat geçirmişlerdir. Öğrenenlerin %27’si Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %10’u ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Öğrenme malzemelerinin tamamına ortalama erişimleri

en fazla olan grup, Yüksek Erişim grubudur. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; çıkmış sınav soruları, deneme sınavı ve ünite özetidir.

Yüksek Puan grubunda, 111.679 öğrenen bulunmaktadır. Öğrenenlerin %19'u bu kümede yer almaktadır. Bu öğrenenlerin tamamı, 34-41 yaş aralığındadır. Bu grupta cinsiyetler açısından eşit bir dağılım gözlenmektedir. Öğrenenlerin %82'si çalışmaktadır. Bu gruptaki öğrenenlerin %45'i ikinci üniversite kapsamında kayıtlıdır. Bu gruptaki öğrenenlerin dönem sonu ortalama puanları, 47'dir. En yüksek dönem sonu ortalama puanına bu gruptaki öğrenenler sahiptir. Bu gruptaki öğrenenlerin sınava girme oranı, diğer gruplardan daha yüksek olmakla birlikte Ortalama Altı ve Ortalama Üstü Puan grubundaki öğrenenlerle benzer özelliktedir. Bu gruptaki öğrenenler, dönem boyunca ortalama 9 gün ve 14 defa oturum açmışlardır. Öğrenenlerin %47'si ilk oturumlarını Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 2., 3. ve 11. haftalar olarak belirlenmiştir. Bu haftalar, ekle-sil ve ara sınav öncesi haftalarıdır. Öğrenenler, ortalama 59 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 16 saat geçirmişlerdir. Öğrenenlerin %24'ü Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %7'si ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; çıkmış sınav soruları, ünite özeti ve deneme sınavıdır.

Ortalama Üstü Puan grubunda, 176.617 öğrenen bulunmaktadır. Öğrenenlerin %30'u bu kümede yer almaktadır. Bu öğrenenlerin tamamı, 26-33 yaş aralığındadır. Öğrenenlerin %45'i erkek, %55'i kadındır. Öğrenenlerin %64'ü çalışmaktadır. Bu gruptaki öğrenenlerin %41'i ikinci üniversite kapsamında kayıtlıdır. Öğrenenlerin dönem sonu ortalama puanları, 43'tür. Bu gruptaki öğrenenlerin sınava girme oranı oldukça yüksektir. Bu gruptaki öğrenenler, dönem boyunca ortalama 7 gün ve 11 defa oturum açmışlardır. Öğrenenlerin %40'ı ilk oturumlarını Ekim ayında, %32'si ise Aralık ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 11. ve 3. haftalar olarak belirlenmiştir. Bu haftalar, ara sınav öncesi ve ekle-sil haftalarıdır. Öğrenenler, ortalama 47 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 13 saat geçirmişlerdir. Öğrenenlerin %21'i Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %6'sı ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; ünite özeti, çıkmış sınav soruları ve deneme sınavıdır.

Ortalama Altı Puan grubunda, 116.128 öğrenen bulunmaktadır. Öğrenenlerin %19'u bu kümede yer almaktadır. Bu öğrenenlerin tamamı, 25 ve altı yaş aralığındadır. Öğrenenlerin %38'i erkek, %62'si kadındır. Bu küme, kadın öğrenen oranının en yüksek olduğu gruptur. Öğrenenlerin %29'u çalışmaktadır, %56'sı ise öğrencidir. Bu grup, öğrenci oranı açısından en yüksek değere sahip gruptur. Bu gruptaki öğrenenlerin %45'i ikinci üniversite kapsamında kayıtlıdır. Bu gruptaki öğrenenlerin dönem sonu ortalama puanları, 39'dur. Düşük Puan grubundan sonra en düşük puan değerine sahip 2. gruptur. Bu gruptaki öğrenenlerin sınava girme oranı oldukça yüksektir. Bu gruptaki öğrenenler, dönem boyunca ortalama 8 gün ve 11 defa oturum açmışlardır. Öğrenenlerin %42'si ilk oturumlarını Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 11. ve 1. haftalar olarak belirlenmiştir. Bu haftalar, ara sınav öncesi ve kayıt haftasıdır. Ara sınav öncesi ilk defa oturum açan öğrenen sayısı oranı, bu grupta en yüksektir. Öğrenenler, ortalama 48 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 15 saat geçirmişlerdir. Öğrenenlerin %21'i Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %7'si ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; ünite özeti, çıkmış sınav soruları ve deneme sınavıdır.

Düşük Puan grubunda, 88.402 öğrenen bulunmaktadır. Öğrenenlerin %15'i bu kümede yer almaktadır. Bu öğrenenlerin %28'i 25 yaş ve altı, %49'u 26-33 ve %23'ü 34-41 yaş aralığında yer almaktadır. Öğrenenlerin %47'si erkek, %53'ü kadındır. Öğrenenlerin %67'si çalışmaktadır. Bu gruptaki öğrenenlerin %58'i ikinci üniversite kapsamında kayıtlıdır ve bu oran diğer kümelere göre daha yüksektir. Öğrenenlerin dönem sonu ortalama puanları, 5'tir. Bu gruptaki öğrenenlerin sınava girme oranı oldukça düşüktür. Öğrenenlerin büyük çoğunluğunun final sınavına girmediği görülmektedir. Bu gruptaki öğrenenler, dönem boyunca ortalama 3 gün ve 4 defa oturum açmışlardır. Öğrenenlerin %51'i ilk oturumlarını Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 11. ve 3. haftalar olarak belirlenmiştir. Bu haftalar, ara sınav öncesi ve ekle-sil haftalarıdır. Öğrenenler, ortalama 21 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 9 saat geçirmişlerdir. Öğrenenlerin %10'u Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %6'sı ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne

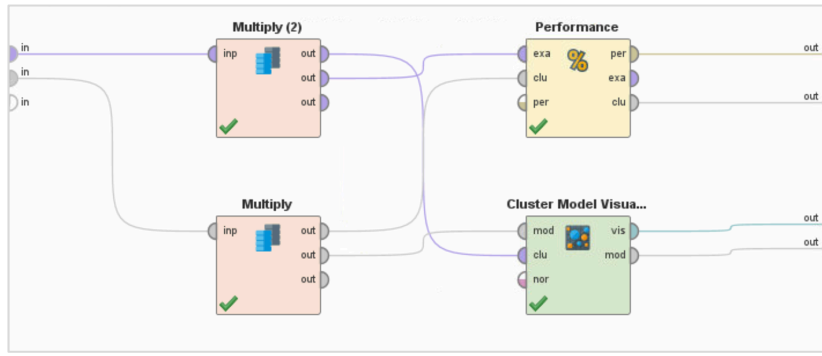
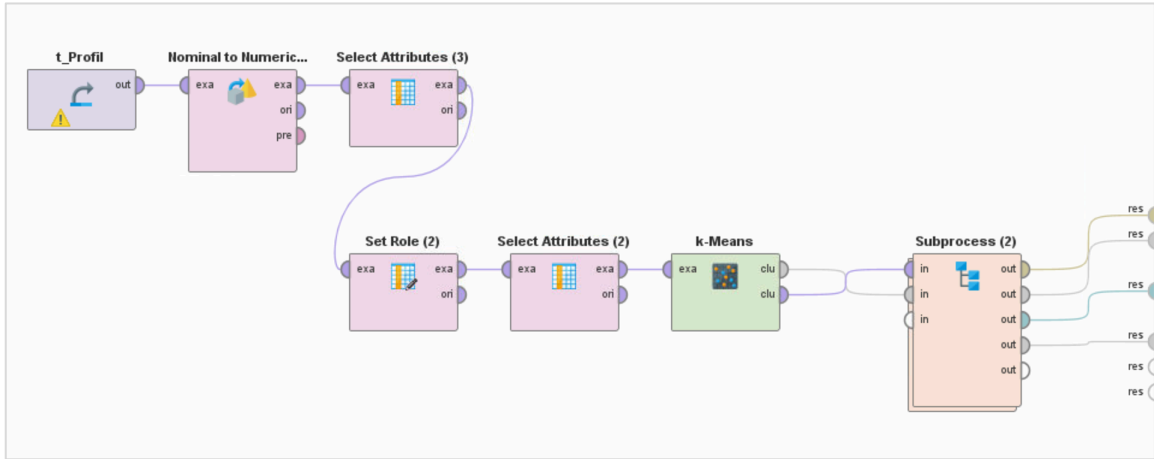
sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; ünite özeti, çıkmış sınav soruları ve ünite metnidir.

4.3.2. k-Means Algoritması ile elde edilen öğrenen profilleri

Bu araştırmada k-Means algoritması, RapidMiner Studio yazılımında çalıştırılmıştır. k-Means analizi öncesinde kategorik özniteliklerde kukla kodlama (dummy coding) yapılmıştır. TwoStep analizinden elde edilen bilgiler ve öznitelik mühendisliği sonuçları değerlendirilerek aşağıdaki öznitelikler ile en yüksek kümeleme performansına erişilmiştir:

- Çıkmış Sınav Soruları Erişim Sayısı
- Deneme Sınavı Erişim Sayısı
- Ders Kitabı Erişim Sayısı
- Dönem Sonu Ortalama Puan
- Günlük Ortalama Oturum Açma Sayısı
- İlk Oturum Ayı=11
- Kullanılan Malzeme Türü Sayısı
- Oturum Açılan Gün Sayısı
- Oturum Sayısı
- Sınava Girme Oranı
- Toplam Faaliyet Sayısı
- Toplam Faaliyet Süresi (dk)
- Yaş

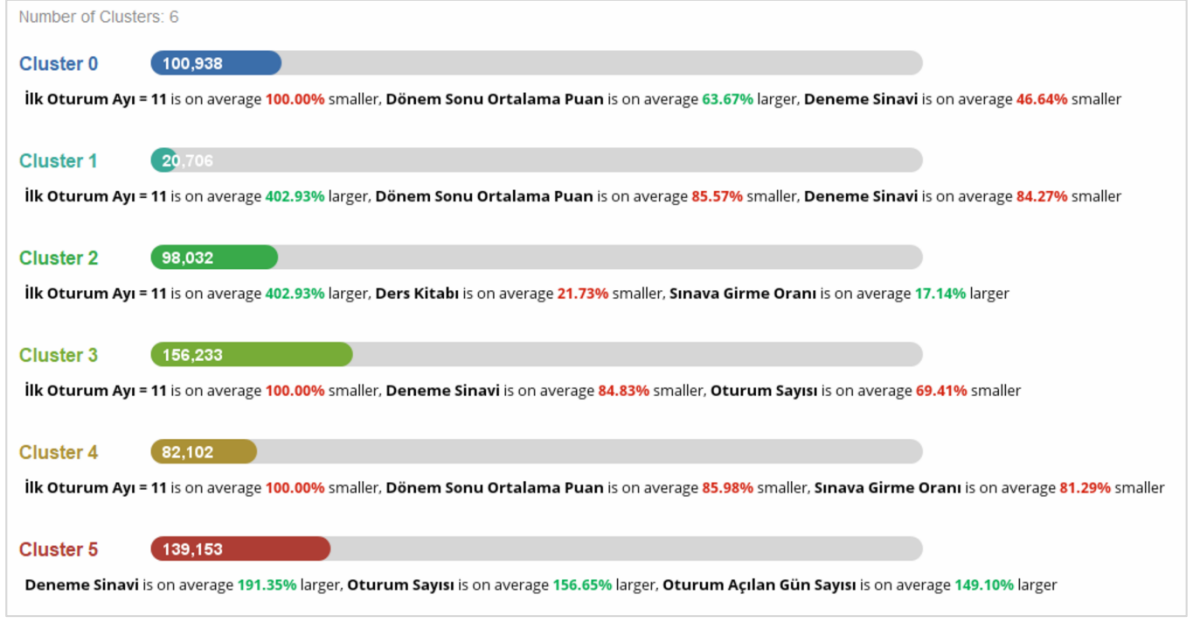
Bu değerlendirme sonucunda, k-Means algoritmasında 13 değişken analize alınmış ve 4, 5 ve 6 küme sayısı ile çalışma yapılmıştır. Kümeleme performansı Davies Bouldin indeksi (DBI) ile belirlenmiştir. Bu analizlerde DBI değeri sırasıyla 0,922; 0,860 ve 0,953 olarak hesaplanmıştır. Yapılan işlemler, Görsel 4.12’de sunulmuştur.



Görsel 4.12. *k-Means algoritması işlem adımları*

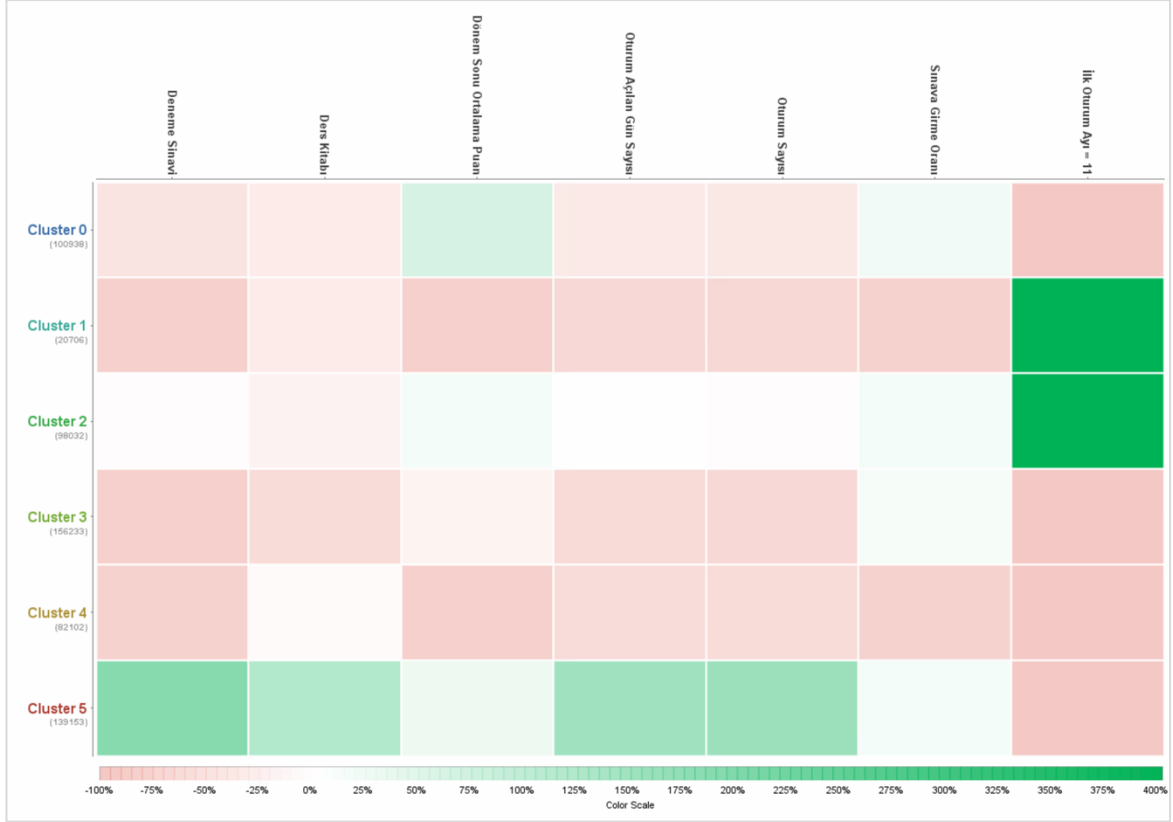
Küme sayısı 6 olarak girildiğinde diğer analiz sonuçlarında yer almayan farklı bir akademik performans ve öğrenme malzemeleri erişim örüntüsüne sahip küme elde edilmiştir. Bu nedenle değerlendirmeler, 6 küme sayısı ile elde edilen sonuçlar üzerinden gerçekleştirilmiştir. Öğrenenlerin %26'sı Küme 3'te, %23'ü Küme 5'te, %17'si Küme 0'da, %16'sı Küme 2'de, %14'ü Küme 4'te ve %4'ü Küme 1'de yer almaktadır. En fazla öğrenen sayısı Küme 2'de, en az öğrenen sayısı ise Küme 1'dedir.

Küme dağılımları, Görsel 4.13'te verilmiştir.



Görsel 4.13. *k*-Means küme dağılımları

Kümeler arasındaki temel farkları gösteren ısı haritası (heat map), Şekil 4.11’de sunulmuştur.



Şekil 4.11. k-Means sonuçları ısı haritası

Isı haritası incelendiğinde, Küme 5, Küme 2 ve Küme 0’ın ilgili öznitelikler bağlamında diğer kümelerden daha farklı olduğu görülmektedir. Küme 3 ve 4 ise birbirine benzer özellikler göstermektedir. Küme 1 ve 2, ilk oturum ayı açısından diğer kümelerden farklılaşmaktadır.

TwoStep algoritması ile elde edilen kümelerde düşük dönem sonu ortalama puan ve düşük öğrenme malzemeleri erişim grupları birbirine benzer özellikler gösterdikleri için birleştirilerek değerlendirilmiştir. Benzer durum, k-Means algoritması ile elde edilen kümelerde de gözlenmiştir. Bu nedenle, Küme 1 ve Küme 4 birlikte değerlendirilmiştir. Öğrenen profillerinin belirlenmesi veri setinde dönem sonu ortalama puanı 0 olan öğrenenler filtrelediğinde öğrenenlerin dönem sonu ortalama puanı 40,48 ve ortalama malzeme erişimi

53,15 olarak hesaplanmıştır. Bu iki değer göz önüne alınarak kümeler aşağıdaki şekilde isimlendirilmiştir:

- Küme 0, en yüksek dönem sonu ortalamasına sahip gruptur. Bu gruptaki öğrenenlerin öğrenme malzemeleri erişimleri ise ortalamanın altındadır. Bu küme, “Yüksek Puan Grubu” olarak isimlendirilmiştir.
- Küme 1 ve 4, en düşük dönem sonu ortalama puan değerine sahiptir. Bu küme, “Düşük Puan Grubu” olarak isimlendirilmiştir.
- Küme 2’nin dönem sonu ortalama puanı ortalamanın üstünde, malzeme erişimi ise ortalama değerdedir. Bu küme, “Ortalama Üstü Puan Grubu” olarak isimlendirilmiştir.
- Küme 3’ün dönem sonu ortalama puanı ortalamanın altındadır. Öğrenme malzemeleri erişimi en düşük kümedir. Bu küme, “Ortalama Altı Puan Grubu” olarak isimlendirilmiştir.
- Küme 5, en yüksek öğrenme malzemeleri erişimine sahip gruptur. Ortalama dönem sonu puanları, genel ortalamanın üstündedir. Bu küme, “Yüksek Erişim Grubu” olarak isimlendirilmiştir.

Yüksek Erişim grubunda, 139.153 öğrenen bulunmaktadır. Öğrenenlerin %23’ü bu kümede yer almaktadır. Bu öğrenenlerin %31’i 26-33 yaş aralığındadır ve diğer yaş grupları birbirine yakın oranlardadır (%23). Öğrenenlerin %42’si erkek, %58’i kadındır. Öğrenenlerin %63’ü çalışmaktadır. Bu gruptaki öğrenenlerin %48’i ikinci üniversite kapsamında kayıtlıdır. Öğrenenlerin dönem sonu ortalama puanları, 47’dir. Bu gruptaki öğrenenlerin sınava girme oranı %100’e yakındır. Öğrenenler, dönem boyunca ortalama 18 gün ve 29 defa oturum açmışlardır. Bu değerler, diğer gruplardaki değerlerin 2 katından daha fazladır. Öğrenenlerin %79’u ilk oturumlarını Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 2. ve 3. haftalar olarak belirlenmiştir. Bu haftalar, ekle-sil haftalarıdır. Bu gruptaki öğrenenlerin kaydolduktan hemen sonra sisteme giriş yaptıkları söylenebilir. Öğrenenler, ortalama 118 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 33 saat geçirmişlerdir. Bu değerler, diğer gruplardaki değerlerden oldukça yüksektir. Öğrenenlerin %57’si Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %18’i ise Ses

Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Öğrenme malzemelerinin tamamına ortalama erişimleri en fazla olan grup, Yüksek Erişim grubudur. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; deneme sınavı, ünite özeti ve çıkmış sınav sorularıdır.

Yüksek Puan grubunda, 100.938 öğrenen bulunmaktadır. Öğrenenlerin %17'si bu kümede yer almaktadır. Bu öğrenenlerin %34'ü 26-33, %28'i 34-41, %23'ü 42 ve üstü ve %15'i 25 ve altı yaş aralığındadır. Bu grupta cinsiyetler açısından eşit bir dağılım gözlenmektedir. Öğrenenlerin %68'i çalışmaktadır. Bu gruptaki öğrenenlerin %57'si ikinci üniversite kapsamında kayıtlıdır. Öğrenenlerin dönem sonu ortalama puanları, 61'dir. En yüksek dönem sonu ortalama puanına bu gruptaki öğrenenler sahiptir. Bu gruptaki öğrenenlerin sınava girme oranı, diğer gruplardan daha yüksektir. Bu gruptaki öğrenenler, dönem boyunca ortalama 5 gün ve 8 defa oturum açmışlardır. Bunlar, ortalama üstü puan gruplarındaki en düşük değerlerdir. Öğrenenlerin %49'u ilk oturumlarını Ekim, %45'i ise Aralık ayında açmıştır. İlk oturum haftaları ise yoğun olarak 2., 3. ve 11. haftalar olarak belirlenmiştir. Bu haftalar, ekle-sil ve ara sınav öncesi haftalarıdır. Öğrenenler, ortalama 35 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 9 saat geçirmişlerdir. Öğrenenlerin %8'i Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %7'si ise Ders Kitabı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; çıkmış sınav soruları, ünite özeti ve deneme sınavlarıdır.

Ortalama Üstü Puan grubunda, 98.032 öğrenen bulunmaktadır. Öğrenenlerin %16'sı bu kümede yer almaktadır. Bu öğrenenlerin %38'i 26-33, %24'ü 25 ve altı, %22'si 34-41 ve %17'si 42 ve üstü yaş aralığındadır. Öğrenenlerin %43'ü erkek, %58'i kadındır. Öğrenenlerin %62'si çalışmaktadır. Bu gruptaki öğrenenlerin %45'i ikinci üniversite kapsamında kayıtlıdır. Öğrenenlerin dönem sonu ortalama puanları, 43'tür. Bu gruptaki öğrenenlerin sınava girme oranı %95'in üstündedir. Bu gruptaki öğrenenler, dönem boyunca ortalama 8 gün ve 12 defa oturum açmışlardır. Bu gruptaki öğrenenlerin tamamı ilk oturumlarını Kasım ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 6-9. haftalar arasındadır. Öğrenenlerin tamamı, ara sınavın gerçekleşeceği ay ilk oturumlarını açmışlardır. Öğrenenler, ara sınava en az 2 hafta kala en az 1 kere oturum açmışlardır. Öğrenenler, ortalama 51 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 14 saat

geçirmişlerdir. Öğrenenlerin %22'si Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %7'si ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; ünite özeti, çıkmış sınav soruları ve deneme sınavlarıdır.

Ortalama Altı Puan grubunda, 156.233 öğrenen bulunmaktadır. Öğrenenlerin %26'sı bu kümede yer almaktadır. Bu öğrenenlerin %41'i 26-33, %29'u 25 ve altı, %19'u 34-41 ve %11'i 42 ve üstü yaş grubundadır. Bu grupta cinsiyetler açısından eşit bir dağılım gözlenmektedir. Öğrenenlerin %60'ı çalışmaktadır. Bu grup, öğrenci oranı açısından en yüksek değere sahip gruptur. Bu gruptaki öğrenenlerin %34'ü ikinci üniversite kapsamında kayıtlıdır. Bu gruptaki öğrenenlerin dönem sonu ortalama puanları, 30'dur. Düşük Puan grubundan sonra en düşük puan değerine sahip 2. gruptur. Bu gruptaki öğrenenlerin sınava girme oranı %95'in üstündedir. Bu gruptaki öğrenenler, dönem boyunca ortalama 3 gün ve 4 defa oturum açmışlardır. Öğrenenlerin %48'i ilk oturumlarını Aralık, %40'ı ise Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 11. ve 3. haftalar olarak belirlenmiştir. Bu haftalar, ara sınav öncesi ve ekle-sil haftasıdır. Ara sınav öncesi ilk defa oturum açan öğrenen sayısı oranı, bu grupta en yüksektir. Öğrenenler, ortalama 18 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 6 saat geçirmişlerdir. Bu grup, tüm kümeler arasında en düşük erişime sahip gruptur. Öğrenenlerin %5'i Deneme Sınavı ⇒ Çıkmış Sınav Soruları, %4'ü ise Ünite Metni, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; çıkmış sınav soruları, ünite özeti ve ünite metnidir.

Düşük Puan grubunda, 102.808 öğrenen bulunmaktadır. Öğrenenlerin %17'si bu kümede yer almaktadır. Bu öğrenenlerin, %42'si 26-33, %24'ü 25 yaş ve altı, %20'si 34-41 ve %15'i 42 ve üstü yaş aralığında yer almaktadır. Öğrenenlerin %47'si erkek, %53'ü kadındır. Öğrenenlerin %70'i çalışmaktadır. Çalışan öğrenen oranı bu kümede diğerlerinden daha yüksektir. Bu gruptaki öğrenenlerin %59'u ikinci üniversite kapsamında kayıtlıdır ve bu oran diğer kümelere göre daha yüksektir. Öğrenenlerin dönem sonu ortalama puanları, 5'tir. Bu gruptaki öğrenenlerin sınava girme oranı %10'un altındadır. Öğrenenlerin büyük çoğunluğunun final sınavına girmediği görülmektedir. Bu gruptaki öğrenenler, dönem boyunca ortalama 4 gün ve 5 defa oturum açmışlardır. Öğrenenlerin %52'si ilk oturumlarını

Ekim ayında açmışlardır. İlk oturum haftaları ise yoğun olarak 3. ve 11. haftalar olarak belirlenmiştir. Bu haftalar, ekle-sil ve ara sınav öncesi haftalarıdır. Öğrenenler, ortalama 22 defa öğrenme malzemelerine erişmişler ve sistemde ortalama 9 saat geçirmişlerdir. Öğrenenlerin %10'u Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları, %6'sı ise Ses Tabanlı Malzemeler, Video, Ünite Özeti ⇒ Çıkmış Sınav Soruları çalışma örüntüsüne sahiptir. Bu gruptaki öğrenenlerin en çok eriştikleri malzemeler sırasıyla; ünite özeti, çıkmış sınav soruları ve ünite metnidir.

4.3.3. Öğrenen profilleri modellerinin değerlendirilmesi

Öğrenen profillerinin belirlenmesi için kümeleme analizi kullanılmıştır. Bu amaçla TwoStep ve k-Means algoritmaları kullanılmıştır. TwoStep ve k-Means algoritmalarında girdi olarak kullanılan öznitelikler ve veri türleri Tablo 4.2'de verilmiştir.

Tablo 4.2. *Profillerin belirlenmesinde girdi olarak kullanılan öznitelikler*

TwoStep		k-Means	
Girdi	Tür	Girdi	Tür
1. Çıkmış Sınav Soruları Erişim Sayısı	Sayısal	1. Çıkmış Sınav Soruları Erişim Sayısı	Sayısal
2. Deneme Sınavı Erişim Sayısı	Sayısal	2. Deneme Sınavı Erişim Sayısı	Sayısal
3. Ders Kitabı Erişim Sayısı	Sayısal	3. Ders Kitabı Erişim Sayısı	Sayısal
4. Dönem Sonu Ortalama Puan	Sayısal	4. Dönem Sonu Ortalama Puan	Sayısal
5. Oturum Açılan Gün Sayısı	Sayısal	5. Günlük Ortalama Oturum Açma Sayısı	Sayısal
6. Oturum Sayısı	Sayısal	6. İlk Oturum Ayı=11	Sayısal
7. Sınava Girme Oranı	Sayısal	7. Kullanılan Malzeme Türü Sayısı	Sayısal
8. Toplam Faaliyet Süresi (dk)	Sayısal	8. Oturum Açılan Gün Sayısı	Sayısal
9. Ünite Metni Erişim Sayısı	Sayısal	9. Oturum Sayısı	Sayısal
10. Ünite Özeti Erişim Sayısı	Sayısal	10. Sınava Girme Oranı	Sayısal
11. Video Erişim Sayısı	Sayısal	11. Toplam Faaliyet Sayısı	Sayısal
12. Yaş Grubu	Sıralı	12. Toplam Faaliyet Süresi (dk)	Sayısal
		13. Yaş	Sayısal

TwoStep algoritmasında 1 sıralı, 11 sayısal olmak üzere toplam 12 girdi kullanılmıştır. k-Means algoritmasında ise 13 sayısal girdi kullanılmıştır. Girdilerin belirlenmesinde veri ön işleme aşamasında gerçekleştirilen öznitelik seçimi sonuçları ve analizler sonucunda elde

edilen kümeleme performansı sonuçları etkili olmuştur. Yapılan tekrarlı analizler sonucunda TwoStep algoritması ile 7 küme elde edilmiş ve küme performansını gösteren Silhouette değeri 0,5 olarak hesaplanmıştır. Bu değer, yapılan kümeleme analizinin başarılı olduğunu göstermektedir. k-Means algoritması ile 6 küme elde edilmiş ve küme performansını değerlendiren DBI değeri 0,953 olarak hesaplanmıştır. Bu değer küçüldükçe kümeleme analizinin daha başarılı olduğu belirtilmektedir.

TwoStep ve k-Means algoritmaları ile elde edilen kümeler, öğrenenlerin dönem sonu ortalama puan ve öğrenme malzeme erişimleri göz önüne alınarak isimlendirilmiştir. En düşük dönem sonu ortalama puanına sahip kümeler benzer özellikler gösterdikleri için aynı isim altında gruplandırılmışlardır. Bu işlemin ardından her iki analiz sonucunda da Yüksek Puan Grubu, Yüksek Erişim Grubu, Ortalama Üstü Puan Grubu, Ortalama Altı Puan Grubu ve Düşük Puan Grubu olmak üzere 5 grup oluşturulmuştur. TwoStep ile elde edilen kümelerde öğrenenlerin yaş grubu kümelerin ayrılmasında büyük etkiye sahip olmuştur. Bu analiz sonucunda düşük puanlara sahip gruplara ait bilgi edinilmiş ancak yüksek puan grupları hakkında çok fazla bilgi edinilememiştir. TwoStep ile elde edilen kümelerin dönem sonu ortalama puanları birbirinden farklı olmakla birlikte k-Means algoritması ile karşılaştırdığında birbirlerine yakın değerlerde oldukları da söylenebilir. k-Means algoritması ile elde edilen kümelerde ise dönem sonu ortalama sınav puanı, ilk oturum açılan ay, toplam faaliyet sayısı ve oturum sayısı gibi daha çok öğrenme sürecine yönelik girdiler kümelerin ayrılmasında etkili olmuştur. Kümeler ayrıntılı olarak incelendiğinde, k-Means ile elde edilen kümelerin Açıköğretim Sistemindeki öğrenenlere yönelik daha fazla bilgi sunduğu görülmüştür. Şekil 4.12’de k-Means ile elde edilen kümelerin cinsiyet ve yaş dağılımları sunulmaktadır.



Şekil 4.12. *Kümelerin cinsiyet ve yaş dağılımları*

Kümelerdeki öğrenenlerin cinsiyet dağılımlarına bakıldığında; Düşük Puan, Ortalama Altı Puan ve Yüksek Puan gruplarında kadın-erkek oranının eşit olduğu, Yüksek Erişim ve Ortalama Üstü Puan gruplarında ise kadın öğrenen oranının diğer gruplara oranla daha fazla olduğu söylenebilir. Yaş değişkeni açısından incelendiğinde Düşük Puan ve Ortalama Altı Puan grubundaki öğrenenlerin daha küçük yaş ortalamasına, Yüksek Erişim ve Yüksek Puan gruplarındaki öğrenenlerin ise daha yüksek yaş ortalamasına sahip olduğu söylenebilir.

Şekil 4.13'te grupların ilk oturum açtıkları ay ve hafta bilgileri yer almaktadır.


İlk Oturum Açılan Ay		Eylül	Ekim	Kasım	Aralık	Ocak
Düşük Puan Grubu		%2,21	%52,09	%20,14	%22,69	%2,86
Ortalama Altı Puan Grubu		%0,99	%40,20		%47,54	%11,26
Ortalama Üstü Puan Grubu				%100,00		
Yüksek Erişim Grubu		%4,98	%79,01		%15,30	%0,71
Yüksek Puan Grubu		%1,28	%48,90		%44,52	%5,30

İlk Oturum Açılan Hafta		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Düşük Puan Grubu		%9,81	%10,84	%15,07	%13,53	%6,53	%5,67	%5,49	%4,14	%3,37	%5,88	%13,79	%2,28	%0,57	%0,45	%0,73	%1,81	%0,05
Ortalama Altı Puan Grubu		%5,17	%9,09	%11,28	%10,73	%4,92					%10,38	%24,18	%10,76	%1,71	%1,47	%2,43	%7,56	%0,32
Ortalama Üstü Puan Grubu						%6,96	%26,50	%24,94	%20,72	%20,88								
Yüksek Erişim Grubu		%17,10	%21,68	%21,20	%17,51	%6,50					%6,71	%7,84	%0,48	%0,21	%0,17	%0,24	%0,36	%0,01
Yüksek Puan Grubu		%6,24	%13,18	%13,04	%12,25	%5,47					%11,16	%22,25	%9,71	%1,06	%0,82	%1,17	%3,48	%0,17

Şekil 4.13. Kümelerin ilk oturum açma tarihleri

Ortalama Üstü Puan grubundaki öğrenenlerin tamamı ilk oturumlarını Kasım ayında açmışlar, diğer gruplar ise çoğunlukla Ekim ayında açmışlardır. Bunun yanı sıra, Yüksek Puan ve Ortalama Altı Puan grubundaki öğrenenlerin %40'tan fazlasının sisteme ilk girişlerinin Aralık ayında olması dikkat çekici bir sonuç olarak değerlendirilebilir. İlk oturum açılan haftalardaki öğrenen sayıları dönem ilerledikçe azalmakla birlikte ara sınav öncesi olan 11. haftada tekrar yükselmiştir. Şekil 4.13'te Yüksek Puan ve Ortalama Altı Puan gruplarının ilk oturum açtıkları hafta örüntüleri açısından birbirine benzer olduğu, Ortalama Üstü Puan grubunun ise diğer kümelerden farklı bir örüntü sergilediği görülmektedir.

Şekil 4.14'te grupların ortalama sınav puanları ve ortalama sistem kullanımları verilmiştir.




Şekil 4.14. Grupların ortalama sınav puanları ve ortalama sistem kullanımları

Grupların ortalama sınav puanları incelendiğinde tüm gruplarda ara sınav puanlarının dönem sonu sınav puanlarına göre daha yüksek olduğu görülmektedir. Bu fark özellikle Düşük Puan Grubunda daha fazladır. Grupların ortalama sınav puanları birbirinden farklı olmakla birlikte Ortalama Üstü Puan ve Yüksek Erişim Gruplarındaki öğrenenlerin puanlarının birbirine yakın olduğu görülmektedir. Sistem kullanımları açısından değerlendirildiğinde, Yüksek Erişim Grubunun diğerlerinden ayrıldığı görülmektedir. Bununla birlikte, Yüksek Puan grubundaki öğrenenlerin sistem kullanımlarının beklenenden daha düşük olduğu söylenebilir.

Grupların öğrenme malzemeleri erişimleri, Şekil 4.15'te sunulmaktadır.

Grupların Ortalama Malzeme Erişimleri



Şekil 4.15. Grupların öğrenme malzemeleri erişimleri

Gruplarda genellikle en çok ünite özeti ve çıkmış sınav soruları kullanımı görülmekle birlikte Yüksek Erişim Grubunda deneme sınavı kullanımı en yüksektir. En düşük kullanımlar ise video ve ders kitabı malzemelerinde gözlenmiştir.

4.4. Akademik Performans Tahmin Modelinin Geliştirilmesi

Öğrenenlerin akademik performanslarına yönelik tahmin modelinin geliştirilmesi için 2019-2020 öğretim yılı Güz dönemi BIL101U dersindeki veriler ile çalışılmıştır. Bu amaç doğrultusunda 56.810 öğrenene ait 30 Eylül 2019-20 Ocak 2020 tarihleri arasındaki faaliyetleri içeren veriler analiz edilmiştir. İlk analizler 18.595 öğrenene ait veriler ile gerçekleştirilmiş ancak tahmin doğruluğu %60'ın üstüne çıkamamıştır. Tahmin doğruluğunu yükseltmek için yapılabilecek işlemlerden bir tanesi sentetik veri üretmektir. Ancak bu işlemde de hata payı olması ve verinin doğal yapısını yansıtamayabileceği düşünülerek veri temizleme işlemine geri dönmüş ve harf notu hesaplanmayan öğrenenler hariç diğer öğrenenlerin verileri veri setine yeniden dahil edilmiştir. Bunun sonucunda 56.810 öğrenene ait öğrenme yönetim sistemindeki hareketleri, demografik özellikleri ve sınav notlarının yer aldığı veri seti oluşturulmuştur. Yapılan aykırı değer analizi sonucunda 5.299 kayıt filtrelenmiş ve veri setinde 51.511 kayıt kalmıştır.

Tahmin modelinin geliştirilmesinde makine öğrenmesi ve derin öğrenme algoritmaları kullanılmıştır. Analizlerde öncelikle özniteliklerin özellikleri ve aralarındaki ilişkiler belirlenmiş, bunun sonrasında öznitelik seçimi yapılmıştır. Bu çalışmada öğrenenlerin BIL101U dersindeki harf notlarının tahmin edilmesi amaçlanmaktadır. AÖS'te AA, AB, BA, BB, BC, CB, CC, CD, DC, DD ve FF olmak üzere 11 harf notu bulunmaktadır. Analizde bu harf notları ilk harfleri göz önüne alınarak A, B, C, D ve F olarak 5 grupta birleştirilmiştir. Analizlerde tahmin edilecek öznitelik olarak bu öznitelik işaretlenmiştir. Bu işlemlerin ardından RapidMiner Studio yazılımında yer alan ve otomatik tahmin modelleri geliştiren araç kullanılarak analizler gerçekleştirilmiştir. Buradan elde edilen sonuçların iyileştirilmesi için tekrarlı deneysel çalışmalar yapılarak modeller geliştirilmiştir. Bu bölümde algoritmalar bağlamında elde edilen bulgular değerlendirilmektedir.

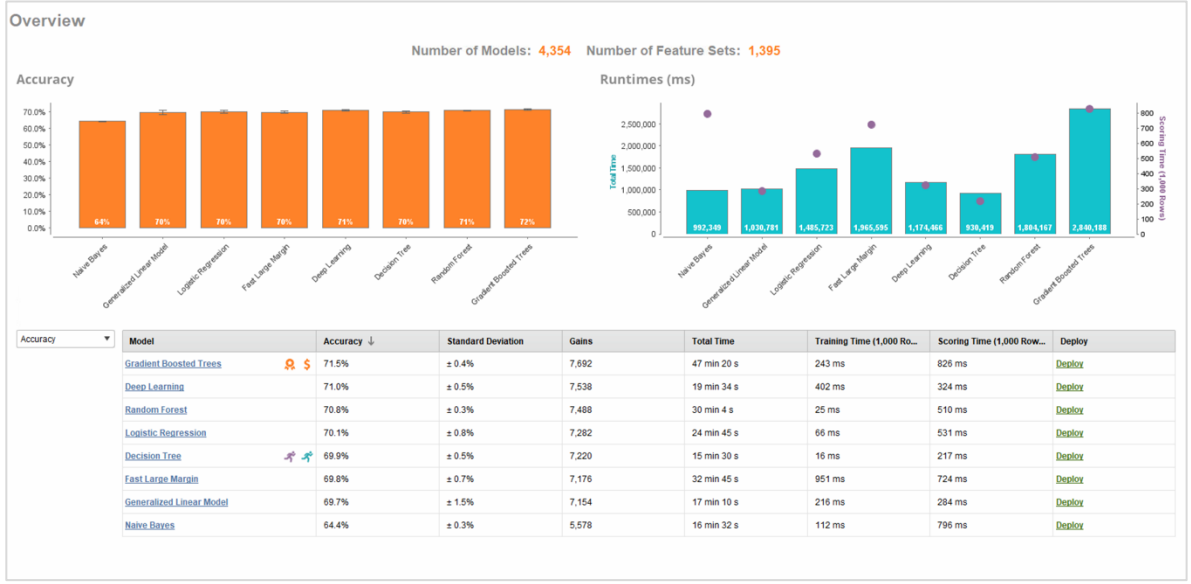
4.4.1. Otomatik Modelleme ile elde edilen tahmin modelleri

Tahmin modelinin geliştirilmesi için 24 girdi alanı seçilmiştir. Özniteliklerin tamamı sayısaldir. Öznitelikler ağırlıklarına göre aşağıda sıralanmıştır:

- Sınava Girme Oranı
- Ara Sınav Puanı

- Deneme Sınavı Ortalama Puanı
- Günlük Ortalama Oturum Açma Sayısı_BIL101U
- Günlük Ortalama Oturum Açma Sayısı_Tamamı
- İlk Oturum Açılan Hafta_BIL101U=Yok
- Oturum Açılan Gün Sayısı_BIL101U
- İlk Oturum Açılan Hafta_Tamamı=Yok
- Oturum Sayısı_BIL101U
- Toplam Faaliyet Sayısı_BIL101U
- Oturum Açılan Gün Sayısı_Tamamı
- Toplam Faaliyet Sayısı_Tamamı
- Çıkmış Sınav Soruları Erişim Sayısı
- Oturum Sayısı_Tamamı
- Ünite Özeti Erişim Sayısı
- Ders Kitabı Erişim Sayısı
- İnfografik Erişim Sayısı
- Video Erişim Sayısı
- Ünite Metni Erişim Sayısı
- Deneme Sınavı Erişim Sayısı
- Ses Tabanlı Malzeme Erişim Sayısı
- Sistemde Geçirilen Süre (dk)_Tamamı
- Sistemde Geçirilen Süre (dk)_BIL101U
- Yaş

Tahmin modeli için belirlenen 24 girdi ile 8 farklı algoritma kullanılarak tahmin modelleri geliştirilmiştir. Her algoritma için tahmin doğruluğunu yükseltecek şekilde farklı öznitelik seçimleri gerçekleştirilmiştir. Otomatik tahmin aracı ile Şekil 4.16'daki sonuçlar elde edilmiştir.



Şekil 4.16. Tahmin modeli geliştirme analiz sonuçları

Tahmin modelinin geliştirilmesi için 8 farklı algoritma ile analiz yapılmıştır. Bu süreçte 1.395 farklı öznelik seti oluşturulmuş ve 4.354 model test edilmiştir. En yüksek tahmin doğruluğu Gradient Boosted Trees (%71,5) ve Deep Learning (%71) algoritmaları ile elde edilmiştir. Bunu Random Forest (%70,8), Logistic Regression (%70,1), Decision Tree (%69,9), Fast Large Margin (%69,8) ve Generalized Linear Model (%69,7) izlemiştir. En düşük tahmin doğruluğu ise Naive Bayes (%64,4) algoritması ile elde edilmiştir.

Naive Bayes algoritması ile yapılan analizde 12 öznelik kullanılmıştır. Bu öznelikler; Sınava Girme Oranı, Günlük Ortalama Oturma Açma Sayısı_BIL101U, Günlük Ortalama Oturma Açma Sayısı_Tamamı, İlk Oturma Açılan Hafta_BIL101U= Yok, Oturma Açılan Gün Sayısı_BIL101U, Toplam Faaliyet Sayısı_BIL101U, Oturma Sayısı_Tamamı, Ünite Özeti Erişim Sayısı, Ders Kitabı Erişim Sayısı, Video Erişim Sayısı, Ses Tabanlı Malzeme Erişim Sayısı ve Yaştır. Bu algoritmanın performans sonuçları, Şekil 4.17'de gösterilmektedir.

Performances						
Criterion	Value					Standard Deviation
Accuracy	64.4%					± 0.3%
Classification Error	35.6%					± 0.3%
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	0	0	0	0	0	0.00%
pred. B	731	2439	1650	283	314	45.02%
pred. C	91	763	1515	432	851	41.48%
pred. D	0	0	0	0	0	0.00%
pred. F	0	2	74	55	5517	97.68%
class recall	0.00%	76.12%	46.77%	0.00%	82.57%	

Şekil 4.17. Naive Bayes algoritması performans sonuçları

Şekil 4.17 incelendiğinde Naive Bayes algoritmasının F (%82,57) ve B (%76,12) harf notlarını tahmin etmede başarılı olduğu ancak A (%0) ve D (%0) harf notlarını doğru bir şekilde tahmin edemediği görülmüştür.

Generalized Linear Model (GLM) algoritması ile yapılan analizde özniteliklerin tamamı (24 adet) kullanılmıştır. Bu algoritmanın performans sonuçları, Şekil 4.18'de gösterilmektedir.

Performances						
Criterion	Value					Standard Deviation
Accuracy	69.7%					± 1.5%
Classification Error	30.3%					± 1.5%
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	298	224	53	7	0	48.55%
pred. B	505	1988	662	72	27	61.09%
pred. C	10	896	2024	477	671	49.63%
pred. D	0	0	3	0	5	0.00%
pred. F	40	97	497	214	5978	87.58%
class recall	32.56%	62.03%	62.49%	0.00%	89.48%	

Şekil 4.18. GLM algoritması performans sonuçları

Şekil 4.18 incelendiğinde GLM algoritmasının F (%89,48), B (%62,03) ve C (%62,49) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %32,56 doğrulukla tahmin ederken D harf notunu ise doğru tahmin edememiştir.

Fast Large Margin (FLM) algoritması ile yapılan analizde 17 öznitelik kullanılmıştır. Bu öznitelikler; Ara Sınav Puanı, Çıkmış Sınav Soruları, Deneme Sınavı, Deneme Sınavı Ortalama Puanı, Ders Kitabı Erişim Sayısı, Günlük Ortalama Oturum Açma Sayısı_Tamamı, İlk Oturum Açılan Hafta_BIL101U=Yok, İnfografik Erişim Sayısı, Oturum Açılan Gün Sayısı_BIL101U, Oturum Sayısı_Tamamı, Ses Tabanlı Malzeme Erişim Sayısı, Sınava Girme Oranı, Sistemde Geçirilen Süre (dk)_BIL101U, Sistemde Geçirilen Süre (dk)_Tamamı, Toplam Faaliyet Sayısı_BIL101U, Toplam Faaliyet Sayısı_Tamamı ve Ünite Metni Erişim Sayısıdır. Bu algoritmanın performans sonuçları, Şekil 4.19'da gösterilmektedir.

Performances						
Criterion	Value					Standard Deviation
Accuracy	69.8%					± 0.7%
Classification Error	30.2%					± 0.7%
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	38	24	2	0	0	59.38%
pred. B	776	2279	826	98	52	56.54%
pred. C	9	899	2252	563	929	48.41%
pred. D	0	0	0	0	0	0.00%
pred. F	0	2	159	109	5701	95.48%
class recall	4.62%	71.13%	69.53%	0.00%	85.32%	

Şekil 4.19. FLM algoritması performans sonuçları

Şekil 4.19 incelendiğinde FLM algoritmasının F (%85,32), B (%71,13) ve C (%69,53) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma A (%4,62) harf notunu çok düşük bir doğrulukla tahmin etmiş, D (%0) harf notunu ise doğru tahmin edememiştir.

Decision Tree (DT) algoritması yapılan ile analizde 10 öznitelik kullanılmıştır. Bu öznitelikler; Ara Sınav Puanı, Sınava Girme Oranı, İnfografik Erişim Sayısı, Toplam Faaliyet Sayısı_Tamamı, İlk Oturum Açılan Hafta_BIL101U=Yok, Günlük Ortalama Oturum Açma Sayısı_Tamamı, Oturum Açılan Gün Sayısı_BIL101U, Sistemde Geçirilen Süre (dk)_BIL101U, Ses Tabanlı Malzeme Erişim Sayısı ve Yaş'tır. Bu algoritmanın performans sonuçları, Şekil 4.20'de gösterilmektedir.

Performances						
Criterion	Value					Standard Deviation
Accuracy	69.9%					± 0.5%
Classification Error	30.1%					± 0.5%
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	141	125	39	1	0	46.08%
pred. B	682	2558	1137	130	132	55.14%
pred. C	0	522	2063	617	1020	48.86%
pred. D	0	0	0	0	0	0.00%
pred. F	0	0	0	22	5529	99.60%
class recall	17.13%	79.81%	63.69%	0.00%	82.76%	

Şekil 4.20. DT algoritması performans sonuçları

Şekil 4.20 incelendiğinde DT algoritmasının F (%82,76), B (%79,81) ve C (%63,69) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma A (%17,13) harf notunu çok düşük bir doğrulukla tahmin etmiş, D (%0) harf notunu ise doğru tahmin edememiştir.

Logistic Regression (LR) algoritması ile yapılan analizde 7 öznitelik kullanılmıştır. Bu öznitelikler; Sınava Girme Oranı, İlk Oturum Açılan Hafta_Tamamı=Yok, Oturum Açılan Gün Sayısı_Tamamı, Ses Tabanlı Malzeme Erişim Sayısı, Ara Sınav Puanı, Deneme Sınavı Ortalama Puanı ve Sistemde Geçirilen Süre (dk)_Tamamı'dır. Bu algoritmanın performans sonuçları, Şekil 4.21'de gösterilmektedir.

Performances						
Criterion	Value					Standard Deviation
Accuracy	70.1%					± 0.8%
Classification Error	29.9%					± 0.8%
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	303	276	67	1	0	46.83%
pred. B	518	2329	1003	117	96	57.32%
pred. C	2	596	2003	537	899	49.62%
pred. D	0	0	0	1	0	100.00%
pred. F	0	4	166	114	5686	95.24%
class recall	36.82%	72.67%	61.84%	0.13%	95.11%	

Şekil 4.21. LR algoritması performans sonuçları

Şekil 4.21 incelendiğinde LR algoritmasının F (%85,11), B (%72,67) ve C (%61,84) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %36,82 doğrulukla tahmin ederken D (%0,13) harf notunu ise çok düşük bir doğrulukla tahmin edebilmiştir.

Random Forest (RF) algoritması ile yapılan analizde 9 öznitelik kullanılmıştır. Bu öznitelikler; Sınava Girme Oranı, Ara Sınav Puanı, Sistemde Geçirilen Süre (dk)_Tamamı, İlk Oturum Açılan Hafta_Tamamı=Yok, Ünite Özeti Erişim Sayısı, Ünite Metni Erişim Sayısı, İnfografik Erişim Sayısı, Günlük Ortalama Oturum Açma Sayısı_Tamamı ve Oturum Açılan Gün Sayısı_Tamamı'dır. Bu algoritmanın performans sonuçları, Şekil 4.22'de gösterilmektedir.

Performances						
Criterion	Value		Standard Deviation			
Accuracy	70.8%		± 0.3%			
Classification Error	29.2%		± 0.3%			
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	3	4	0	0	0	42.86%
pred. B	820	2600	1107	131	108	54.55%
pred. C	0	596	1884	457	624	52.91%
pred. D	0	3	2	22	33	36.67%
pred. F	0	1	246	160	5917	93.56%
class recall	0.36%	81.15%	58.17%	2.86%	88.55%	

Şekil 4.22. RF algoritması performans sonuçları

Şekil 4.22 incelendiğinde RF algoritmasının F (%88,55), B (%81,15) ve C (%58,17) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, D (%2,86) ve A (%0,36) harf notlarını ise çok düşük bir doğrulukla tahmin edebilmiştir.

Deep Learning (DL) algoritması ile yapılan analizde 9 öznitelik kullanılmıştır. Bu öznitelikler; Sınava Girme Oranı, Ara Sınav Puanı, Toplam Faaliyet Sayısı_Tamamı, Toplam Faaliyet Sayısı_Ders, Sistemde Geçirilen Süre (dk)_Tamamı, Çıkmış Sınav Soruları Erişim Sayısı, İlk Oturum Açılan Hafta_Tamamı=Yok, Yaş ve Video Erişim Sayısıdır. Bu algoritmanın performans sonuçları, Şekil 4.23'te gösterilmektedir.

Performances						
Criterion	Value					Standard Deviation
Accuracy	71.0%					± 0.5%
Classification Error	29.0%					± 0.5%
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	197	121	33	2	0	55.81%
pred. B	626	2705	1289	164	149	54.83%
pred. C	0	371	1761	483	745	52.41%
pred. D	0	1	0	0	0	0.00%
pred. F	0	7	156	121	5787	95.32%
class recall	23.94%	84.40%	54.37%	0.00%	86.62%	

Şekil 4.23. DL algoritması performans sonuçları

Şekil 4.23 incelendiğinde DL algoritmasının F (%86,62), B (%84,40) ve C (%54,37) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %23,94 doğrulukla tahmin ederken D (%0) harf notunu ise doğru tahmin edememiştir.

Gradient Boosted Trees (GBT) algoritması ile yapılan analizde 13 öznelik kullanılmıştır. Bu öznelikler; Sınava Girme Oranı, Ara Sınav Puanı, Günlük Ortalama Oturum Açma Sayısı_Tamamı, Günlük Ortalama Oturum Açma Sayısı_BIL101U, Ses Tabanlı Malzeme Erişim Sayısı, Toplam Faaliyet Sayısı_Tamamı, Ünite Metni Erişim Sayısı, Oturum Sayısı_Tamamı, Sistemde Geçirilen Süre (dk)_BIL101U, Çıkmış Sınav Soruları Erişim Sayısı, Oturum Açılan Gün Sayısı_Tamamı, Sistemde Geçirilen Süre (dk)_Tamamı ve İlk Oturum Açılan Hafta_BIL101U=Yok'tur. Bu algoritmanın performans sonuçları, Şekil 4.24'te gösterilmektedir.

Performances						
Criterion	Value	Standard Deviation				
Accuracy	71.5%	± 0.4%				
Classification Error	28.5%	± 0.4%				
Confusion Matrix						
	true A	true B	true C	true D	true F	class precision
pred. A	307	246	52	1	0	50.66%
pred. B	515	2280	966	126	76	57.53%
pred. C	0	665	1904	394	489	53.82%
pred. D	0	0	4	21	1	80.77%
pred. F	0	13	413	228	6116	90.34%
class recall	37.35%	71.16%	55.70%	2.73%	91.53%	

Şekil 4.24. GBT algoritması performans sonuçları

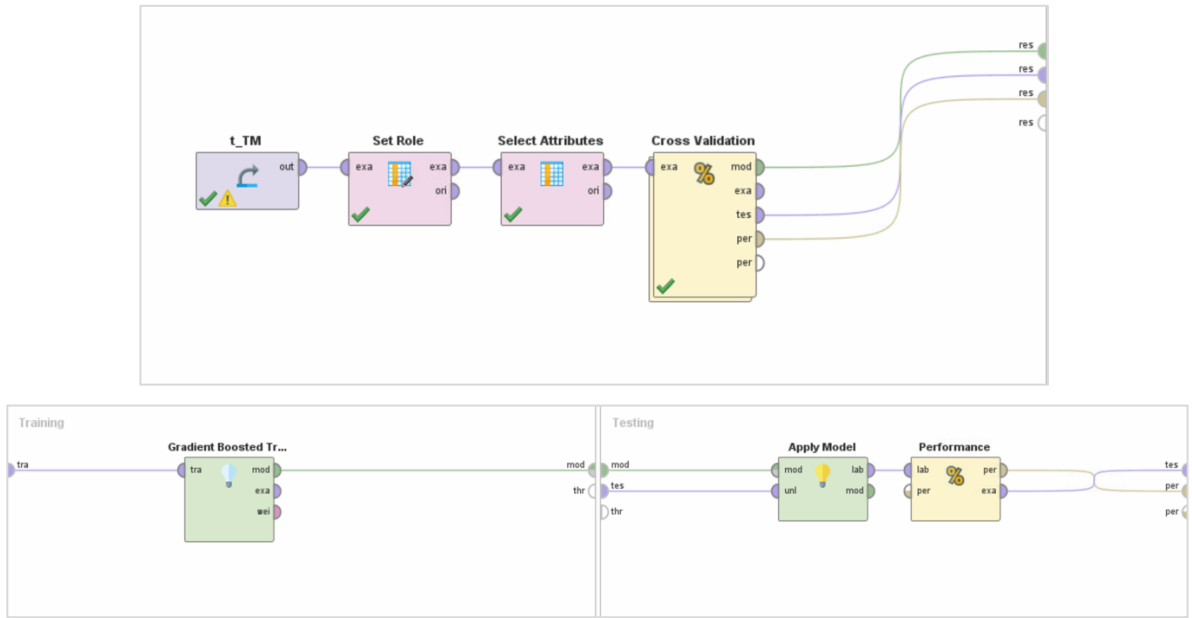
Şekil 4.24 incelendiğinde GBT algoritmasının F (%91,53), B (%71,16) ve C (%55,70) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %37,35 doğrulukla tahmin ederken D (%2,73) harf notunu ise çok düşük bir doğrulukla tahmin edebilmiştir.

Yapılan analizler incelendiğinde algoritmaların F harf notunu yüksek doğruluk oranları ile tahmin edebildikleri belirlenmiştir. D harf notu ise neredeyse hiç tahmin edilememiştir. Elde edilen bu sonuçların ardından tahminlerin iyileştirilmesi için DL ve GBT algoritmalarıyla analizlere devam edilmiştir.

4.4.2. GBT algoritması tahmin modeli

Otomatik kümeleme sonuçlarından yararlanılarak GBT algoritmasında öznelik setleri ve parametre değerlerinde değişiklikler yapılarak analizlere devam edilmiştir. En yüksek tahmin doğruluğu %72,16 olarak elde edilmiştir. Analizde sadece ilgili derse ait öznelikler yer almaktadır. Öğrenenlerin diğer derslerdeki çalışmalarına yönelik veriler analizden çıkarılmıştır. Analizde Ara Sınav Notu, Deneme Sınavı Notu, Sınava Girme Oranı, Oturum Sayısı_BIL101U, Oturum Açılan Gün Sayısı_BIL101U, Toplam Faaliyet Sayısı_BIL101U, Sistemde Geçirilen Süre (dk)_BIL101U, Çıkmış Sınav Soruları Erişim Sayısı, İlk Oturum Açılan Hafta_BIL101U=Yok, Günlük Ortalama Oturum Açma Sayısı_BIL101U ve Yaş olmak üzere 11 girdi yer almaktadır. Analizde ağaç sayısı 150, maksimum derinlik 5 ve öğrenme hızı ise 0,03 olarak girilmiştir. Verilerin eğitim ve test gruplarına ayrılması için her

harf notundan eşit oranda örnekleme oluşturulmasını sağlayan tabakalı örnekleme yöntemi seçilmiştir. Aşırı öğrenmenin engellenmesi için ezberlemeden önce durma (early stopping) seçeneği işaretlenmiştir. Elde edilen model, performansın kontrol edilmesi ve istatistiksel yanlılığın önlenmesi için doğrulanmıştır. Algoritma uygulama ekranı, Görsel 4.14’te verilmiştir.



Görsel 4.14. GBT algoritması uygulama ekranı

GBT algoritmasının performans sonuçları, Şekil 4.25’te gösterilmektedir.

accuracy: 72.16% +/- 0.52% (micro average: 72.16%)						
	true A	true B	true C	true D	true F	class precision
pred. A	1040	738	140	7	0	54.03%
pred. B	1836	8192	3473	431	258	57.73%
pred. C	5	2270	6918	1608	2184	53.28%
pred. D	0	0	9	83	6	84.69%
pred. F	0	14	797	565	20937	93.83%
class recall	36.10%	73.05%	61.02%	3.08%	89.53%	

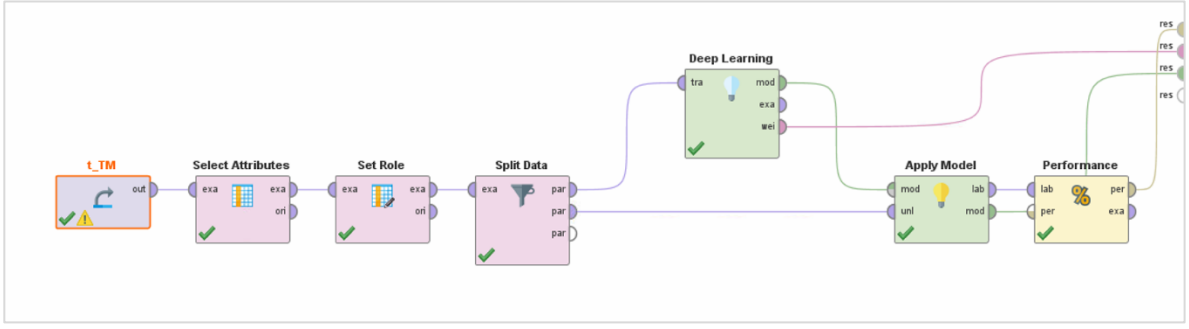
Şekil 4.25. GBT algoritması performans sonuçları

Şekil 4.25 incelendiğinde GBT algoritmasının F (%89,53), B (%73,05) ve C (%61,02) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %36,10 doğrulukla tahmin ederken D (%3,08) harf notunu ise çok düşük bir doğrulukla tahmin edebilmiştir. Bu algoritma ile başarısız olma ihtimali olan öğrenenler yüksek doğruluk değerleri ile tahmin edilebilmektedir. Bu algoritma ile elde edilen model sonucu EK-3'te; A, B, C, D ve F harf notları için elde edilen ağaç açıklamaları ise EK-4, EK-5, EK-6, EK-7 ve EK-8'de sunulmuştur.

GBT ile elde edilen ağaç yapıları incelendiğinde A harf notu için kök düğümü, deneme sınavı puanıdır. Deneme sınavı puanının 0,555'ten küçük ya da büyük eşit olmasına göre ağaç yapısı oluşmaktadır. B harf notunun tahmin edilmesi ağacındaki kök düğümü de deneme sınavı puanıdır. Bu değer 0,808'den küçük ya da büyük eşit olmasına göre ağaç yapısı oluşmaktadır. C harf notunun tahmin edilmesi ağacındaki kök düğümü, Toplam Faaliyet Sayısı_BIL101U'dur. Bu değer 0,027'den küçük ya da büyük eşit olmasına göre ağaç yapısı oluşmaktadır. D harf notunun tahmin edilmesi ağacındaki kök düğümü, ara sınav puanıdır. Bu değer 0,467'den küçük ya da büyük eşit olmasına göre ağaç yapısı oluşmaktadır. Son olarak F harf notunun tahmin edilmesi ağacındaki kök düğümü, sınava girme oranıdır. Bu değer 0,500'den küçük ya da büyük eşit olmasına göre ağaç yapısı oluşmaktadır. GBT algoritması ile geliştirilen ağaçlar incelendiğinde her harf notunun tahmininde farklı bir ağaç yapısı ortaya çıktığı görülmektedir. Burada özellikle F harf notunun tahmininde sınava girme oranının kök düğüm olarak belirlenmesi dikkat çekici bir sonuç olarak değerlendirilebilir. Sadece ara sınav puanı ve sınava girme oranı öznitelikleri kullanılarak algoritma yeniden çalıştırıldığında tahmin doğruluğu %71,46, analize Toplam Faaliyet Sayısı_BIL101U özniteliği de dahil edildiğinde tahmin doğruluğu %71,66 olarak hesaplanmıştır. Analize İlk Oturum Açılan Hafta_BIL101U=Yok özniteliği dahil edildiğinde ise tahmin doğruluğu %71,81 olarak hesaplanmıştır. Bu sonuçlar incelendiğinde sadece ara sınav notu ve sınava girme oranı öznitelikleri ile elde edilen model doğruluğu ile 11 öznitelik ile elde edilen model doğruluğuna oldukça yakın değerde olduğu görülmektedir.

4.4.3. DL algoritması tahmin modeli

Otomatik kümeleme sonuçlarından yararlanılarak DL algoritmasında öznitelik setleri ve parametre değerlerinde değişiklikler yapılarak analizlere devam edilmiştir. En yüksek tahmin doğruluğu %72,01 olarak elde edilmiştir. Bu tahmin doğruluğuna ulaşmak için önce çeşitli denemeler yapılmıştır. Öncelikle gözlemlerin %85'i eğitim, %15'i test amacıyla ayrılmıştır. Verilerin eğitim ve test gruplarına ayrılması için her harf notundan eşit oranda örneklem oluşturulmasını sağlayan tabakalı örneklem yöntemi seçilmiştir. Derin öğrenme algoritmasında aktivasyon fonksiyonu olarak ExpRectifier seçilmiş ve 3 gizli katman oluşturulmuştur. Bu katmanların boyutları 200, 100 ve 50 olarak girilmiştir. Algoritmada 1 girdi katmanı, 3 gizli katman ve 1 çıktı katmanı bulunmaktadır. Girdi katmanında 8 öznitelik bulunmaktadır. Çıktı katmanının boyutu ise 5'tir ve aktivasyon fonksiyonu Softmax'tir. Öğrenme hızı ve momentum değerleri için ayarlanabilir oran seçilmiştir. Kayıp fonksiyonu ve dağılım fonksiyonu otomatik olarak belirlenmektedir. Aşırı öğrenmenin engellenmesi için ezberlemeden önce durma (early stopping) seçeneği işaretlenmiştir. Bu ayarlar dışındaki ayarlar varsayılan değerlerde bırakılmıştır. GBT algoritması sonuçlarından yararlanılarak öncelikle Ara Sınav Notu ve Sınava Girme Oranı öznitelikleri ile analiz gerçekleştirilmiş ve tahmin doğruluğu %70,65 olarak hesaplanmıştır. Bu analize İlk Oturum Açılan Hafta_BIL101U=Yok özniteliği dahil edildiğinde ise tahmin doğruluğu %71,33 olarak hesaplanmıştır. Analize Toplam Faaliyet Sayısı_BIL101U ve Video Erişim Sayısı öznitelikleri dahil edildiğinde tahmin doğruluğu %71,45, Yaş dahil edildiğinde %71,84 olmuştur. Son olarak İlk Oturum Açılan Hafta_BIL101U=Yok özniteliği çıkarılıp Oturum Sayısı_BIL101U, Yaş, Ders Kitabı Erişim Sayısı ve Canlı Ders Kayıtları Erişim Sayısı eklendiğinde tahmin doğruluğu %72,01'e ulaşmıştır. Algoritma uygulama ekranı, Görsel 4.15'te verilmiştir.



Görsel 4.15. DL algoritması uygulama ekranı

DL algoritmasının performans sonuçları, Şekil 4.26'da gösterilmektedir.

accuracy: 72.01%						
	true A	true B	true C	true D	true F	class precision
pred. A	201	163	37	1	0	50.00%
pred. B	230	1163	516	79	34	57.52%
pred. C	1	356	1090	259	364	52.66%
pred. D	0	0	0	0	0	0.00%
pred. F	0	0	58	65	3110	96.20%
class recall	46.53%	69.14%	64.08%	0.00%	88.65%	

Şekil 4.26. DL algoritması performans sonuçları

Şekil 4.26 incelendiğinde DL algoritmasının F (%88,65), B (%69,14) ve C (%64,08) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %46,53 doğrulukla tahmin ederken D (%0) harf notunu ise doğru tahmin edememiştir. Bu algoritma ile başarısız olma ihtimali olan öğrenenler yüksek doğruluk değerleri ile tahmin edilebilmektedir. Bu algoritma ile elde edilen model sonucu EK-9'da sunulmuştur. DL algoritması ile gerçekleştirilen analizdeki öznelitliklerin önem değerleri ise aşağıdaki şekilde sıralanmıştır:

1. Ara Sınav Puanı
2. Sınava Girme Oranı
3. Toplam Faaliyet Sayısı_BIL101U
4. Canlı Ders Kayıtları Erişim Sayısı
5. Oturum Sayısı_BIL101U
6. Ders Kitabı Erişim Sayısı

7. Video Eriřim Sayısı
8. Yař

DL algoritması ile elde edilen tahmin modelindeki en önemli özniteliklerin ara sınav puanı ve sınava girme oranı olduđu belirlenmiřtir. Bu iki öznitelik, GBT algoritması ile elde edilen modelde de yüksek önem deęerine sahiptir.

4.4.4. Akademik performans tahmin modellerinin deęerlendirilmesi

Akademik performans tahmin modellerinin oluřturulması için makine öğrenmesi ve derin öğrenme algoritmaları kullanılmıřtır. Tahmin modelinin geliştirilmesi için Gradient Boosted Trees (GBT), Deep Learning (DL), Random Forest (RF), Logistic Regression (LR), Decision Tree (DT), Fast Large Margin (FLM), Generalized Linear Model (GLM) ve Naive Bayes (NB) olmak üzere 8 farklı algoritma ile analiz yapılmıřtır. Algoritmalar bağlamında en yüksek tahmin gücüne sahip öznitelikler, Tablo 4.3'te verilmiřtir.

Tablo 4.3. Algoritmalar bağlamında en yüksek tahmin gücüne sahip özellikler

Gradient Boosted Trees	Deep Learning
<ol style="list-style-type: none"> 1. Ara Sınav Puanı 2. Deneme Sınavı Puanı 3. Sınava Girme Oran 4. Oturum Sayısı_BIL101U 5. Oturum Açılan Gün Sayısı_BIL101U 6. Toplam Faaliyet Sayısı_BIL101U 7. Sistemde Geçirilen Süre (dk)_BIL101U 8. Çıkmış Sınav Soruları Erişim Sayısı 9. İlk Oturum Açılan Hafta_BIL101U=Yok 10. Günlük Ortalama Oturum Açma Sayısı_BIL101U 11. Yaş 	<ol style="list-style-type: none"> 1. Ara Sınav Puanı 2. Sınava Girme Oranı 3. Toplam Faaliyet Sayısı_BIL101U 4. Video Erişim Sayısı 5. Oturum Sayısı_BIL101U 6. Yaş 7. Ders Kitabı Erişim Sayısı 8. Canlı Ders Kayıtları Erişim Sayısı
Random Forest	Decision Tree
<ol style="list-style-type: none"> 1. Sınava Girme Oranı 2. Ara Sınav Puanı 3. Sistemde Geçirilen Süre (dk)_Tamamı 4. İlk Oturum Açılan Hafta_Tamamı=Yok 5. Ünite Özeti Erişim Sayısı 6. Ünite Metni Erişim Sayısı 7. İnfografik Erişim Sayısı 8. Günlük Ortalama Oturum Açma Sayısı_Tamamı 9. Oturum Açılan Gün Sayısı_Tamamı 	<ol style="list-style-type: none"> 1. Ara Sınav Puanı 2. Sınava Girme Oranı 3. İnfografik Erişim Sayısı 4. Toplam Faaliyet Sayısı_Tamamı 5. İlk Oturum Açılan Hafta_BIL101U=Yok 6. Günlük Ortalama Oturum Açma Sayısı_Tamamı 7. Oturum Açılan Gün Sayısı_BIL101U 8. Sistemde Geçirilen Süre (dk)_BIL101U 9. Ses Tabanlı Malzeme Erişim Sayısı 10. Yaş
Fast Large Margin	Generalized Linear Model
<ol style="list-style-type: none"> 1. Ara Sınav Puanı 2. Çıkmış Sınav Soruları Erişim Sayısı 3. Deneme Sınavı Erişim Sayısı 4. Deneme Sınavı Ortalama Puanı 5. Ders Kitabı Erişim Sayısı 6. Günlük Ortalama Oturum Açma Sayısı_Tamamı 7. İlk Oturum Açılan Hafta_BIL101U=Yok 8. İnfografik Erişim Sayısı 9. Oturum Açılan Gün Sayısı_BIL101U 10. Oturum Sayısı_Tamamı 11. Ses Tabanlı Malzeme Erişim Sayısı 12. Sınava Girme Oranı 13. Sistemde Geçirilen Süre (dk)_BIL101U 14. Sistemde Geçirilen Süre (dk)_Tamamı 15. Toplam Faaliyet Sayısı_BIL101U 16. Toplam Faaliyet Sayısı_Tamamı 17. Ünite Metni Erişim Sayısı 	<ol style="list-style-type: none"> 1. Sınava Girme Oranı 2. Ara Sınav Puanı 3. Deneme Sınavı Ortalama Puanı 4. Günlük Ortalama Oturum Açma Sayısı_BIL101U 5. Günlük Ortalama Oturum Açma Sayısı_Tamamı 6. İlk Oturum Açılan Hafta_BIL101U=Yok 7. Oturum Açılan Gün Sayısı_BIL101U 8. İlk Oturum Açılan Hafta_Tamamı=Yok 9. Oturum Sayısı_BIL101U 10. Toplam Faaliyet Sayısı_BIL101U 11. Oturum Açılan Gün Sayısı_Tamamı 12. Toplam Faaliyet Sayısı_Tamamı 13. Çıkmış Sınav Soruları Erişim Sayısı 14. Oturum Sayısı_Tamamı 15. Ünite Özeti Erişim Sayısı 16. Ders Kitabı Erişim Sayısı 17. İnfografik Erişim Sayısı 18. Video Erişim Sayısı 19. Ünite Metni Erişim Sayısı 20. Deneme Sınavı Erişim Sayısı 21. Ses Tabanlı Malzeme Erişim Sayısı 22. Sistemde Geçirilen Süre (dk)_Tamamı 23. Sistemde Geçirilen Süre (dk)_BIL101U 24. Yaş
Logistic Regression	Naive Bayes
<ol style="list-style-type: none"> 1. Sınava Girme Oranı 2. İlk Oturum Açılan Hafta_Tamamı=Yok 3. Oturum Açılan Gün Sayısı_Tamamı 4. Ses Tabanlı Malzeme Erişim Sayısı 5. Ara Sınav Puanı 6. Deneme Sınavı Ortalama Puanı 7. Sistemde Geçirilen Süre (dk)_Tamamı 	<ol style="list-style-type: none"> 1. Sınava Girme Oranı 2. Günlük Ortalama Oturum Açma Sayısı_BIL101U 3. Günlük Ortalama Oturum Açma Sayısı_Tamamı 4. İlk Oturum Açılan Hafta_BIL101U=Yok 5. Oturum Açılan Gün Sayısı_BIL101U 6. Toplam Faaliyet Sayısı_BIL101U 7. Oturum Sayısı_Tamamı 8. Ünite Özeti Erişim Sayısı 9. Ders Kitabı Erişim Sayısı 10. Video Erişim Sayısı 11. Ses Tabanlı Malzeme Erişim Sayısı 12. Yaş

Tablo 4.3'te yer alan “_BIL101U” uzantılı öznitelikler öğrenenlerin sadece BIL101U dersindeki verilerini, “_Tamamı” uzantılı öznitelikler ise kayıtlı oldukları tüm derslerdeki verilerini kapsamaktadır. LR algoritması en az öznitelik ile GLM algoritması ise en fazla öznitelik ile tahmin modeli oluşturmuştur. Yapılan analizlerde akademik performans tahmini için ayırt ediciliği en yüksek öznitelikler, ara sınav puanı ve sınava girme oranı olarak belirlenmiştir.

En yüksek tahmin doğrulukları, GBT (%72,16) ve DL (%72,01) algoritmaları ile elde edilmiştir. Bunu RF (%70,8), LR (%70,1), DT (%69,9), FLM (%69,8) ve GLM (%69,7) algoritmaları izlemiştir. En düşük tahmin doğruluğu ise NB algoritması (%64,4) ile elde edilmiştir. AÖS verileri ile akademik tahmin modelinin geliştirilmesinde ağaç tabanlı algoritmalar ve derin sinir ağları en iyi sınıflayıcılar, Bayes tabanlı algoritma ise en düşük tahmin doğruluğunu veren sınıflayıcı olarak belirlenmiştir. Algoritmaların F harf notunu yani dersten kalan öğrenenleri başarılı bir şekilde tahmin ettikleri ancak A ve D harf notlarını tahmin etmede başarısız oldukları görülmüştür.

4.5. Öğrenme Analitikleri Tabanlı Performans Değerlendirme Paneli Uygulaması

PDP, 2020-2021 öğretim yılı Bahar dönemi boyunca Temel Bilgi Teknolojileri II (BIL102U) dersini alan öğrenenlere sunulmuştur. Uygulama, 17 hafta boyunca devam etmiştir. Bu süreç boyunca öğrenenlere ilerleme durumları hakkında günlük olarak bilgiler sunulmuş ve mesajlar gönderilmiştir. Sistem üzerinden toplam 78 metin mesajı, 1 video mesajı ve 6 kısa mesaj (SMS) gönderilmiştir. SMS'ler panelin tanıtılması amacıyla ve dönem süresince sisteme giriş yapmayan öğrenenlere gönderilmiştir.

Motivasyonel mesajlar panelin tanıtılması, ilgili hafta işlenecek ünite ile ilgili bilgi verilmesi, çalışma önerilerinin sunulması, canlı derse katılımın teşvik edilmesi, ilerleme durumu ve deneme sınav puanları hakkında bilgi verilmesi, sınavlar ile ilgili hatırlatmaların yapılması ve sistem kullanımı düşük olan ya da diğer haftalara göre erişimleri düşük öğrenenlerin uyarılması amacıyla hazırlanmıştır. Mesaj örnekleri, Tablo 4.4'te verilmiştir.

Tablo 4.4. PDP mesaj örnekleri

Mesaj Başlığı	Mesaj Metni
Yeni Dönem Başlıyor!	Merhaba Öğrenen Adı, Temel Bilgi Teknolojileri II dersine hoş geldin! Bu derste, temel bilgi teknolojilerinin yaşamımızdaki yeri ve önemi konusunda bilgi sahibi olacaksın. Dönem boyunca mesajlarımla yanında olacağım. Sana özel olarak hazırlanan Performans Değerlendirme Paneli ile Temel Bilgi Teknolojileri II dersindeki durumunu günlük olarak takip edebilirsin. Başarılar dilerim. Prof.Dr. Tevfik Volkan Yüzer
Hadi, Çalışmaya Başlayalım!	Merhaba Öğrenen Adı, Temel Bilgi Teknolojileri II dersinde başarılı olmak için yapman gereken ilk şey çalışmaya başlamak. Hadi, ilk adımı atalım. Nasıl mı? <ul style="list-style-type: none">• Ders kitabını incele.• Öğrenme malzemelerini gözden geçir.• Not al.• Haftalık olarak düzenli çalış.• Tekrar yap. Keyifli bir öğrenme deneyimi diliyorum. Prof.Dr. Tevfik Volkan Yüzer
Performans Değerlendirme Panelinde Neler Var?	Merhaba, ben Prof.Dr. Tevfik Volkan Yüzer. Temel Bilgi Teknolojileri II dersini bu dönem birlikte yürüteceğiz. Mesajlarımla dönem boyunca yanında olacağım ve ilerleme durumunu takip edeceğim. Derse giriş yaptığında ekranın üstünde bazı mesajlar ve grafikler görmüş olmalısın. İşte bu sana özel mesajlardan ve grafiklerden oluşan alan, senin için hazırlanan Performans Değerlendirme Paneli. Bu panelde hem kendi gelişimini hem de diğer arkadaşlarının çalışmalarını görebilirsin. Performans Değerlendirme Panelinde yer alan her şey sana özel. Bu panelde malzeme kullanım durumunu takip edebilirsin. Ayrıca alıştırmaya ve deneme sınavlarından aldığın notları inceleyebilirsin. Sınav notların da bu panoda yer alacak. Performans Değerlendirme Panelinin sol üstünde ise senin için hazırlanmış mesaj kutusu bulunuyor. Seninle buradan iletişime geçeceğim. Mesajları okuduktan sonra lütfen mesajı okudum butonuna tıkla. Performans Değerlendirme Panelindeki veriler her sabah güncelleniyor. Bunun için hadi çalışmaya başla ve öğrenme sürecindeki ilerlemeni günü gününe takip et. Ben de ilerleme durumunu sürekli takip ediyor olacağım. Birlikte güzel bir dönem geçireceğimize inanıyorum, başarılar dilerim.
İkinci Konumuz: Bilişim Güvenliği	Merhaba Öğrenen Adı, Bu haftaki konumuz, Bilişim Güvenliği! Bu üniteye bilişim güvenliğinin temel ilkeleri, kötü amaçlı yazılımlar ve alınabilecek önlemlere odaklanacağız. Ayrıca bu üniteye ait İnfografik malzemesini incelemeni öneriyorum. Başarılar dilerim. Prof.Dr. Tevfik Volkan Yüzer
1. Hafta Öğrenme Malzemeleri Kullanım Durumu	Merhaba Öğrenen Adı, İlk hafta Temel Bilgi Teknolojileri II dersindeki öğrenme malzemelerini kullanmadığını görüyorum. Başlamak için bir öğrenme malzemesine tıklaman ve onu çalışman yeterli. eKampüs'te sen de diğer arkadaşlarına katıl ve öğrenmeye başla. Dersteki performansını yakından takip ediyor olacağım. İyi haftalar dilerim. Prof.Dr. Tevfik Volkan Yüzer

Tablo 4.4. PDP mesaj örnekleri (Devam)

Mesaj Başlığı	Mesaj Metni
Tebrikler!	Merhaba Öğrenen Adı, Deneme sınav notlarının genel ortalamadan daha yüksek olduğunu görüyorum. Azmin ve çalışmaların için seni tebrik ederim. Düzenli çalışmaların ile dersi başarıyla tamamlayacağını düşünüyorum. Bu hafta yıldızlar senin için. Prof.Dr. Tevfik Volkan Yüzer
Tebrikler!	Merhaba Öğrenen Adı, Her hafta düzenli olarak öğrenme malzemelerine çalıştığını görüyorum. Böyle çalışmaya devam ederek başarılı olabilirsin. Dersteki performansını yakından takip ediyor olacağım. Tebrikler, bu hafta yıldızlar senin için! Prof. Dr. Tevfik Volkan Yüzer
Sınavlar Yaklaşıyor!	Merhaba Öğrenen Adı, Bahar dönemi ara sınavları 10 Nisan'da başlıyor. Sınavlarda başarılı olmak için çalışmalarını artırmanı ve tekrar yapmanı öneriyorum. İlk 4 üniteden notlar çıkarabilir, videoları izleyebilir ve soru çözebilirsin. Sınava girmeden önce ders kitabını incelemen ve ilgili bölümleri çalışman oldukça önemli. Bu süreçteki çalışmalarının notuna büyük etkisi olacağını unutmamalısın. Sınavlarında başarılar dilerim. Prof. Dr. Tevfik Volkan Yüzer
Canlı Derse Bekliyorum!	Merhaba Öğrenen Adı, Bu hafta canlı derste Geleceğin Teknolojilerini tartışacağız. Senin de katılımını bekliyorum. Unutma, canlı dersimiz Çarşamba günü saat 11.00'da. Katılmak için derse giriş yaptıktan sonra Canlı Ders butonuna tıklaman yeterli. Canlı derste görüşmek üzere, iyi haftalar dilerim. Prof.Dr. Tevfik Volkan Yüzer
Deneme Sınavı ve Alıştırma Ortalama Puanın!	Merhaba Öğrenen Adı, Ara sınavdan bu yana çözdüğün deneme sınavları ve alıştırma sorularından aldığın notların ortalaması X. Notlarını yükseltmek için konu tekrarı yapmanı ve çalışmalarını artırmanı öneriyorum. İyi çalışmalar dilerim. Prof.Dr. Tevfik Volkan Yüzer
Bahar Dönemi Çalışma Özeti!	Merhaba Öğrenen Adı, Dönem boyunca Temel Bilgi Teknolojileri II dersindeki öğrenme malzemelerini X kere kullandın. En çok kullandığın malzeme, X. Deneme sınavı ve alıştırma not ortalaması ise, X. Öğrenme malzemeleri kullanımının sınıf ortalamasının altında, alıştırma ve deneme sınavları not ortalaması ise sınıf ortalamasının üstünde gözüküyor. Başarılı olmak için sınavdan önce konulara çalışmanı ve tekrar yapmanı öneriyorum. Sınavında başarılar dilerim. Prof.Dr. Tevfik Volkan Yüzer


Mesajların ortalama okunma oranı %9 olmakla birlikte pop-up mesajlarda bu oranın daha yüksek olduđu görülmüştür. Mesajların okunduđu bilgisinin elde edilmesi için öğrenenlerin mesajın altında yer alan “Okudum” butonuna tıklaması gerekmektedir. Bu işlem yapılmadığında mesajlar okunsa da veri alınamamaktadır. Mesaj okunmalarındaki oranın düşük olması, bu durumdan kaynaklanıyor olabilir.

Mesajlar amaçlarına uygun olarak farklı zaman aralıklarında sistemde kalmaktadır. İlgili tarih aralığında sisteme giriş yapmayan öğrenenler mesajları görememektedirler. Mesaj kuralları ise haftalık olarak öğrenenlerin sistem kullanımları, öğrenme malzemeleri erişimleri ve deneme sınavlarından aldıkları notlar analiz edilerek oluşturulmuştur. Böylece mesajların hangi öğrenenlere gideceği belirlenmiştir. Okunma oranı en yüksek olan 15 mesaja ilişkin bilgiler, Tablo 4.5’te sunulmaktadır.

Tablo 4.5. Mesajların okunma oranları

Mesaj Başlığı	Mesaj Kuralı	Mesajın Sistemde Kalma Süresi (Gün)	Mesaj Gönderilen Öğrenen Sayısı	Mesajı Okuyan Öğrenen Sayısı	Mesajın Okunma Oranı
Tebrikler!	3 hafta boyunca her hafta en az 5 malzeme erişimi olan öğrenenler	4	25	17	%68
Önemli!	Tüm öğrenenler	75	13377	7350	%55
4. Hafta Öğrenme Malzemeleri Kullanım Durumun	22-28 Mart 2021 arasında BIL102U dersindeki öğrenme malzemelerine 9 ve üstü erişen öğrenenler	4	225	104	%46
4. Hafta Öğrenme Malzemeleri Kullanım Durumun	22-28 Mart 2021 arasında BIL102U dersindeki öğrenme malzemelerine 2-8 (8 dahil) arası erişen öğrenenler	4	343	125	%36
4. Hafta Öğrenme Malzemeleri Kullanım Durumun	22-28 Mart 2021 arasında BIL102U dersindeki öğrenme malzemelerine 1 kere erişen öğrenenler	4	147	50	%34
Yeni Dönem Başlıyor!	Tüm öğrenenler	39	13377	4328	%32
Temel Bilgi Teknolojileri II Performans Değerlendirme Paneli	Tüm öğrenenler	37	13377	4195	%31
1. Hafta Öğrenme Malzemeleri Kullanım Durumun	1-7 Mart 2021 tarihleri arasında BIL102U dersindeki öğrenme malzemelerine 10 ve üzeri erişen öğrenenler	3	217	67	%31
Hadi, Performans Değerlendirme Panelini Kullanalım!	Tüm öğrenenler	30	13377	4006	%30
Deneme Sınavı ve Alıştırma Ortalama Puanın!	Ara sınavdan mesaj tarihinde kadar deneme sınavı ve alıştırma çözen ve bunların not ortalaması 50'nin altında olan öğrenenler	4	21	6	%29
Tebrikler!	Alıştırma ve deneme sınav notlarının ortalaması 60'ın üzerinde olan öğrenenler	4	159	44	%28
Sınavlar Yaklaşıyor!	Tüm öğrenenler	11	13377	3520	%26
1. Hafta Öğrenme Malzemeleri Kullanım Durumun	1-7 Mart 2021 tarihleri arasında BIL102U dersindeki öğrenme malzemelerine 2-9 (dahil) erişen öğrenenler	3	324	81	%25
PDP Değerlendirme Anketi	Tüm öğrenenler	11	13377	3116	%23
Bahar Dönemi Çalışma Durumun!	Dönem boyunca öğrenme malzeme erişimleri 16 ve üstü olan ve alıştırma ve deneme sınavlarının ortalaması 75'ten düşük olan öğrenenler	7	235	52	%22

Öğrenenlerin mesajları okuduktan sonraki ilk 3 saat içerisinde en çok eriştikleri öğrenme malzemeleri, Şekil 4.27’de verilmiştir.



Şekil 4.27. Mesaj okuma işlemi sonrasında öğrenenlerin öğrenme malzemeleri erişimi

Şekil 4.27 incelendiğinde öğrenenlerin mesajları okuduktan sonra en fazla eriştikleri öğrenme malzemelerinin sırasıyla kitap, çıkmış sınav soruları, ünite özeti ve canlı ders olduğu görülmektedir. En az erişilen malzeme ise eders olarak ortaya çıkmıştır. Buradaki dağılım genel malzeme erişiminden farklıdır. Öğrenenlerin mesajları okuduktan sonra çoğunlukla kitaba erişimleri, genel malzeme kullanım örüntülerinden farklılaşmaktadır.

4.6. Öğrenme Analitikleri Tabanlı Performans Değerlendirme Paneli Uygulamasının Öğrenme Sürecine Etkileri

Çalışmanın 4. araştırma sorusu kapsamında, kitlesel açık ve uzaktan öğrenme sistemlerinde PDP kullanımının öğrenme sürecine etkileri araştırılmıştır. Bu çalışma, 2020-2021 öğretim yılı Bahar dönemi BIL102U dersinde 26.753 öğrenen ile gerçekleştirilmiştir. Bu çalışmada; deney ve kontrol grupları arasında oturum sayıları, oturum açtıkları gün sayısı, öğrenme malzemelerine erişim ve dönem sonu ortalama puanları açısından istatistiksel bir farklılık olup olmadığı bağımsız örneklem t-testi ile incelenmiştir. Test sonuçları, Tablo 4.6’da verilmiştir.

Tablo 4.6. Bağımsız örneklem t-testi sonuçları

Faktör	Grup Türü	n	\bar{x}	SS	t	df	p
Oturum Sayısı	Deney	13.377	1,93	4,08	9,996	25511,615	0,000*
	Kontrol	13.376	1,47	3,26			
Oturum Açılan Gün Sayısı	Deney	13.377	1,53	2,83	10,747	25569,166	0,000*
	Kontrol	13.376	1,19	2,28			
Öğrenme Malzemelerine Erişim	Deney	13.377	6,51	16,19	14,116	23037,519	0,000*
	Kontrol	13.376	4,15	10,58			
Dönem Sonu Ortalama Puan	Deney	13.377	72,98	21,21	3,782	26703,939	0,000*
	Kontrol	13.376	71,98	22,12			

(* $p < 0,001$; \bar{x} : Ortalama; SS: Standart Sapma)

Tablo 4.6 incelendiğinde deney grubunun oturum sayısı ortalaması ($\bar{X} = 1,93$; $SS = 4,08$) ile kontrol grubunun oturum sayısı ortalaması ($\bar{X} = 1,47$; $SS = 3,26$) arasında istatistiksel olarak anlamlı bir farklılık olduğu bulunmuştur ($t(25511,615) = 9,996$; $p < 0,001$). Deney grubundaki öğrenenlerin ortalama oturum açma sayıları, kontrol grubundaki öğrenenlerden daha yüksektir. Etki değeri, $r = 0,06$ olarak hesaplanmıştır.

Yapılan bağımsız örneklem t-testi sonucunda deney grubunun ortalama oturum açtığı gün sayısı ($\bar{X} = 1,53$; $SS = 2,83$) ile kontrol grubunun ortalama oturum açtığı gün sayısı ($\bar{X} = 1,19$; $SS = 2,28$) arasında istatistiksel olarak anlamlı bir farklılık olduğu bulunmuştur ($t(25569,166) = 10,747$; $p < 0,001$). Deney grubundaki öğrenenlerin

ortalama oturum açtığı gün sayısı, kontrol grubundaki öğrenenlerden daha yüksektir. Etki değeri, $r = 0,07$ olarak hesaplanmıştır.

Yapılan bağımsız örneklem t-testi sonucunda deney grubunun ortalama öğrenme malzemeleri erişimi ($\bar{X} = 6,51; SS = 16,19$) ile kontrol grubunun ortalama öğrenme malzemeleri erişimi ($\bar{X} = 4,15; SS = 10,58$) arasında istatistiksel olarak anlamlı bir farklılık olduğu bulunmuştur ($t(23037,519) = 14,116; p < 0,001$). Deney grubundaki öğrenenlerin ortalama öğrenme malzemeleri erişimi, kontrol grubundaki öğrenenlerden daha yüksektir. Etki değeri, $r = 0,09$ olarak hesaplanmıştır.

Yapılan bağımsız örneklem t-testi sonucunda deney grubunun dönem sonu ortalama puanı ($\bar{X} = 72,98; SS = 21,21$) ile kontrol grubunun dönem sonu ortalama puanı ($\bar{X} = 71,98; SS = 22,12$) arasında istatistiksel olarak anlamlı bir farklılık olduğu bulunmuştur ($t(26703,939) = 3,782; p < 0,001$). Deney grubundaki öğrenenlerin dönem sonu ortalama puanı, kontrol grubundaki öğrenenlerden daha yüksektir. Etki değeri, $r = 0,02$ olarak hesaplanmıştır.

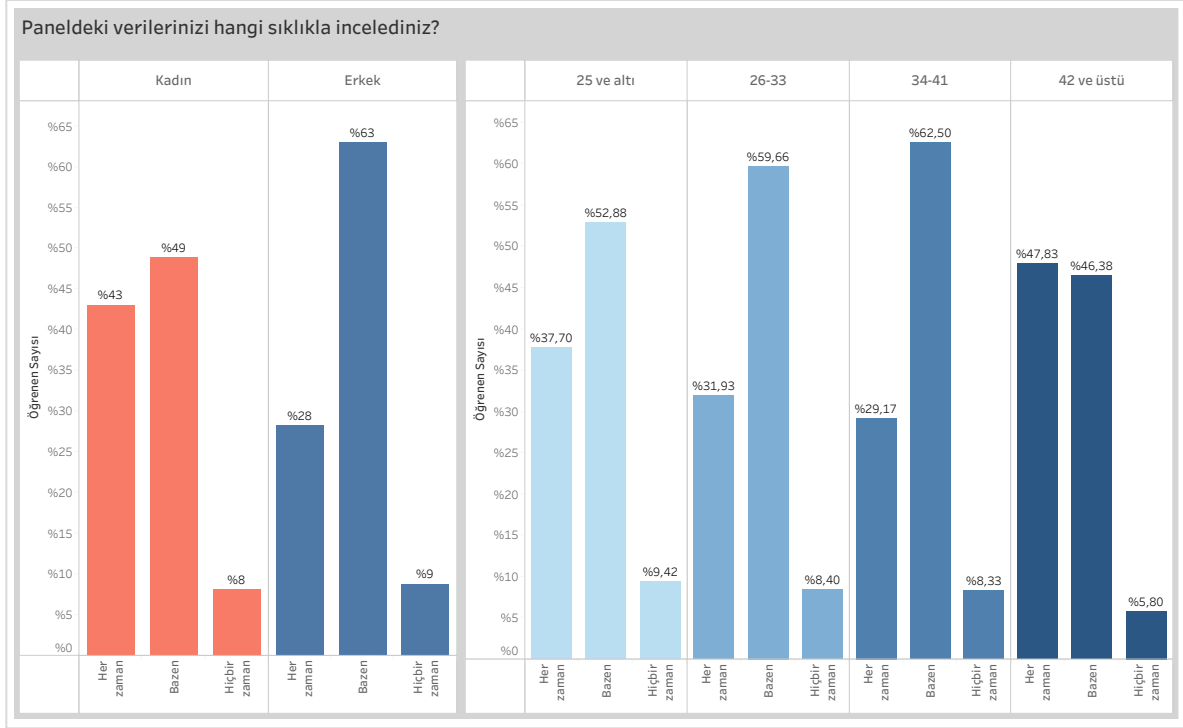
Tablo 4.6 incelendiğinde tüm değişkenler açısından deney ve kontrol grupları arasında istatistiksel olarak anlamlı bir fark olduğu görülmektedir. Ancak bu farkın çok yüksek bir düzeyde olmadığı belirlenmiştir.

4.7. Öğrenme Analitikleri Tabanlı Performans Değerlendirme Paneline Yönelik Öğrenen Görüşlerinin Belirlenmesi

2020-2021 öğretim yılı Bahar dönemi boyunca BIL102U dersinde deney grubundaki öğrenenler ile PDP uygulaması gerçekleştirilmiştir. Dönemin sonunda öğrenenlerin PDP'ye yönelik görüşlerinin ve memnuniyet düzeylerinin belirlenmesi amacıyla bir anket uygulanmıştır. Bu anketi, 451 öğrenen yanıtlamıştır. Anket çalışması, çevrimiçi olarak gerçekleştirilmiştir. Ankete katılım gönüllülük esasına dayanmaktadır. Anket 2 tane 3'lü likert tipi, 25 tane 5'li likert tipi ve 1 tane açık uçlu maddeden oluşmaktadır. Bu maddeler öğrenenlerin PDP kullanımları, mesaj okuma durumları ve PDP'ye yönelik görüşlerinden oluşmaktadır.


Ankette yer alan ilk madde öğrenenlerin paneldeki verilerini inceleme sıklıkları ile ilgilidir. Öğrenenlerin %55,2'si bu verileri bazen incelediğini, %36,4'ü sisteme her giriş

yaptıklarında incelediklerini, %8,4'ü ise hiç incelemediklerini belirtmişlerdir. Bu durum Şekil 4.28'de yaş ve cinsiyet açısından değerlendirilmiştir.



Şekil 4.28. Öğrenenlerin cinsiyet ve yaşları bağlamında PDP'yi inceleme durumları


Öğrenenlerin PDP'yi inceleme sıklıkları göz önüne alındığında her zaman incelediğini belirten kadın öğrenenlerin oranı %43, erkek öğrenenlerin oranı ise %28'dir. Her zaman incelediğini belirten kadınların oranı erkeklerden yüksekken, bazen incelediğini belirten erkeklerin oranı daha yüksektir. Bu durum yaş grupları açısından incelendiğinde yaş gruplarında genellikle bazen giriş yapma durumunun ön planda olduğu görülmektedir. Ancak diğer gruplardan farklı olarak 42 yaş ve üstünde ise öğrenenlerin %48'i her zaman incelediklerini belirtmişlerdir. 42 yaş ve üstündeki öğrenenlerin PDP'yi inceleme durumlarının diğer yaş gruplarına göre daha yüksek olduğu söylenebilir. PDP inceleme sıklığı, Şekil 4.29'da öğrenenlerin harf notları bağlamında incelenmiştir.



Şekil 4.29. Öğrenenlerin harf notları bağlamında PDP'yi inceleme durumları


Öğrenenlerin PDP'yi inceleme sıklıkları harf notları bağlamında incelendiğinde bazen incelediğini belirten öğrenen oranlarının genellikle daha yüksek olduğu görülmektedir. Ancak bu durum AA ve DC harf notları gruplarında farklılaşmaktadır. Bu iki gruptaki öğrenenlerin %50'ye yakın verileri her zaman incelediklerini belirtmişlerdir. Ek olarak, BA grubunda da her zaman ve bazen panel inceleme oranları birbirine oldukça yakındır.

Ankette yer alan ikinci madde öğrenenlerin gönderilen mesajları okuma sıklıkları ile ilgilidir. "Öğretim elemanı tarafından gönderilen mesajları hangi sıklıkla okudunuz?" maddesine öğrenenlerin %51'i bazen, %46,6'sı her zaman, %2,4'ü ise hiçbir zaman okumadıklarını belirtmişlerdir. Bu durum Şekil 4.30'da, yaş ve cinsiyet açısından değerlendirilmiştir.



Şekil 4.30. Öğrenenlerin cinsiyet ve yaşları bağlamında mesajları okuma durumları


Öğretim elemanları tarafından gönderilen mesajları kadınların %50'si, erkeklerin ise %43'ü her zaman okuduklarını belirtmişlerdir. Yaş grupları açısından incelendiğinde 42 ve üstü yaş grubundaki öğrenenlerin her zaman okuma oranının diğer gruplardan daha yüksek olduğu görülmektedir. Öğrenenlerin %1-5'lik bölümünün ise mesajları hiçbir zaman okumadıkları görülmüştür. Mesaj okuma sıklığı, Şekil 4.31'de öğrenenlerin harf notları bağlamında incelenmiştir.



Şekil 4.31. Öğrenenlerin harf notları bağlamında mesaj okuma durumları

Öğrenenlerin harf notları bağlamında mesaj okuma sıklıkları incelendiğinde “Her zaman” yanıtı veren öğrenen oranının en yüksek AA, BA ve DC harf notlarında yer aldığı görülmektedir. “Hiçbir zaman” yanıtının ise en yüksek DC, DD ve FF harf notlarındaki öğrenenler tarafından verildiği belirlenmiştir.

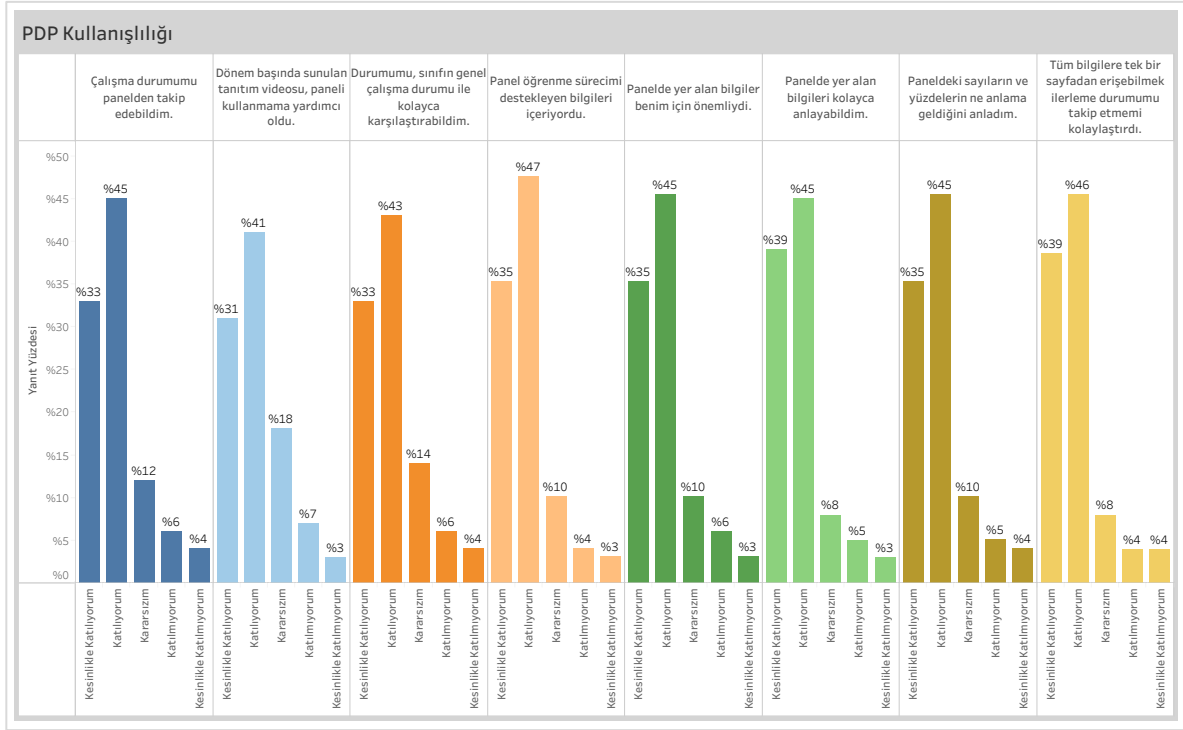
Öğrenenlerin PDP’ye yönelik algılanan fayda boyutundaki görüşleri, Şekil 4.32’de verilmiştir.



Şekil 4.32. PDP'ye yönelik algılanan fayda

Ankette PDP'ye yönelik algılanan fayda boyutunda 6 madde yer almaktadır. “Panel öğrenme hedeflerime ulaşmama yardımcı oldu.” maddesine öğrenenlerin %26’sı kesinlikle katılıyorum, %5’i ise kesinlikle katılmıyorum yanıtını vermiştir. “Panel öğrenme sürecimde motivasyonumu artırdı.” maddesine öğrenenlerin %32’si kesinlikle katılıyorum, %4’ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Panel sayesinde eKampüs’e daha sık giriş yaptım.” maddesine öğrenenlerin %24’ü kesinlikle katılıyorum, %6’sı ise kesinlikle katılmıyorum yanıtını vermiştir. “Panel zaman yönetimine destek oldu.” maddesine öğrenenlerin %29’u kesinlikle katılıyorum, %5’i ise kesinlikle katılmıyorum yanıtını vermiştir. “Paneldeki bilgiler çalışma alışkanlıklarımı düzenlememe yardımcı oldu.” maddesine öğrenenlerin %28’i kesinlikle katılıyorum, %5’i ise kesinlikle katılmıyorum yanıtını vermiştir. “Paneldeki bilgilere dayanarak kendi öğrenme sürecimi planlayabildim.” maddesine öğrenenlerin %28’i kesinlikle katılıyorum, %5’i ise kesinlikle katılmıyorum yanıtını vermiştir. Tüm maddelerde öğrenenlerin %40’tan fazlası katılıyorum yanıtını verirken yaklaşık %15’i de kararsızım yanıtını vermiştir. Bu bulgular değerlendirildiğinde, PDP’ye yönelik algılanan faydanın olumlu olduğu söylenebilir.

Öğrenenlerin PDP'nin kullanılabilirliği boyutundaki görüşleri, Şekil 4.33'te verilmiştir.




Şekil 4.33. PDP kullanılabilirliğine yönelik görüşler

Ankette PDP'nin kullanılabilirliği boyutunda 8 madde yer almaktadır. “Çalışma durumumu panelden takip edebildim.” maddesine öğrenenlerin %33’ü kesinlikle katılıyorum, %4’ü ise kesinlikle katılmıyorum yanıtı vermiştir. “Dönem başında sunulan tanıtım videosu, paneli kullanmama yardımcı oldu.” maddesine öğrenenlerin %31’i kesinlikle katılıyorum, %3’ü ise kesinlikle katılmıyorum yanıtı vermiştir. “Durumumu, sınıfın genel çalışma durumu ile kolayca karşılaştırabildim.” maddesine öğrenenlerin %33’ü kesinlikle katılıyorum, %4’ü ise kesinlikle katılmıyorum yanıtı vermiştir. “Panel öğrenme sürecimi destekleyen bilgileri içeriyordu.” maddesine öğrenenlerin %35’i kesinlikle katılıyorum, %3’ü ise kesinlikle katılmıyorum yanıtı vermiştir. “Panelde yer alan bilgiler benim için önemliydi.” maddesine öğrenenlerin %35’i kesinlikle katılıyorum, %3’ü ise kesinlikle katılmıyorum yanıtı vermiştir. “Panelde yer alan bilgileri kolayca anlayabildim.” maddesine öğrenenlerin %39’u kesinlikle katılıyorum, %3’ü ise kesinlikle katılmıyorum yanıtı vermiştir. “Paneldeki sayıların ve yüzdelerin ne anlama geldiğini anladım.”

maddesine öğrenenlerin %35'i kesinlikle katılıyorum, %4'ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Tüm bilgilere tek bir sayfadan erişebilmek ilerleme durumumu takip etmemi kolaylaştırdı.” maddesine öğrenenlerin %39'u kesinlikle katılıyorum, %4'ü ise kesinlikle katılmıyorum yanıtını vermiştir. Tüm maddelerde öğrenenlerin %40'tan fazlası katılıyorum yanıtını verirken yaklaşık %10'u da kararsızım yanıtını vermiştir. Bu bulgular değerlendirildiğinde, PDP'nin kullanılabilirliğine ilişkin görüşlerin olumlu olduğu görülmektedir.

Öğrenenlerin öğretim elemanı tarafından gönderilen mesajlara yönelik algılanan fayda boyutundaki görüşleri, Şekil 4.34'te verilmiştir.




Şekil 4.34. Mesajlara yönelik algılanan fayda

Ankette mesajlara yönelik algılanan fayda boyutunda 6 madde yer almaktadır. “Aldığım geri bildirimler başarıyı artırdı.” maddesine öğrenenlerin %28'i kesinlikle katılıyorum, %4'ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Aldığım geri bildirimler öğrenme sürecime destek oldu.” maddesine öğrenenlerin %31'i kesinlikle katılıyorum, %4'ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Mesajlarda adımın yer alması öğretim

elemanı tarafından önemsendiğimi hissettirdi.” maddesine öğrenenlerin %39’u kesinlikle katılıyorum, %4’ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Öğretim elemanından geri bildirim almak motivasyonumu artırdı.” maddesine öğrenenlerin %39’u kesinlikle katılıyorum, %4’ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Öğretim elemanından mesaj almak derse katılımımı artırdı.” maddesine öğrenenlerin %28’i kesinlikle katılıyorum, %5’i ise kesinlikle katılmıyorum yanıtını vermiştir. “Öğretim elemanından mesaj almak öğrenme sürecimde yalnız olmadığımı hissettirdi.” maddesine öğrenenlerin %36’sı kesinlikle katılıyorum, %4’ü ise kesinlikle katılmıyorum yanıtını vermiştir. Tüm maddelerde öğrenenlerin %40’tan fazlası katılıyorum yanıtını verirken yaklaşık %10’u da kararsızım yanıtını vermiştir. Bu bulgular değerlendirildiğinde, mesajlara yönelik algılanan faydanın olumlu olduğu söylenebilir.


Öğrenenlerin mesajların kullanılabilirliği boyutundaki görüşleri, Şekil 4.35’te verilmiştir.



Şekil 4.35. Mesajların kullanılabilirliğine ilişkin görüşler

Mesajların kullanılabilirliği boyutunda 2 madde yer almaktadır. “Mesaj içerikleri anlaşılırdı.” maddesine öğrenenlerin %41’i kesinlikle katılıyorum, %46’sı ise katılıyorum yanıtını vermiştir. “Mesaj sıklığı yeterliydi.” maddesine öğrenenlerin %33’ü kesinlikle katılıyorum, %48’i ise katılıyorum yanıtını vermiştir. Her iki maddeye de öğrenenlerin %4’ü kesinlikle katılmıyorum yanıtını vermiştir. Bu bulgular değerlendirildiğinde, mesajların kullanılabilirliğine ilişkin görüşlerin olumlu olduğu görülmektedir.

Ankette son olarak PDP’ye yönelik genel memnuniyet durumu incelenmiştir. Verilen yanıtlar, Şekil 4.36’da gösterilmektedir.



Şekil 4.36. PDP'ye yönelik memnuniyet

Ankette PDP’ye yönelik memnuniyet boyutu 3 maddeden oluşmaktadır. “Bu uygulamanın diğer derslerimde de olmasını isterim.” maddesine öğrenenlerin %39’u

kesinlikle katılıyorum, %4'ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Tüm Açıköğretim öğrencilerinin kullanması gerektiğini düşünüyorum.” maddesine öğrenenlerin %42'si kesinlikle katılıyorum, %4'ü ise kesinlikle katılmıyorum yanıtını vermiştir. “Uygulamayı kullandığım için memnunum.” maddesine öğrenenlerin %38'i kesinlikle katılıyorum, %3'ü ise kesinlikle katılmıyorum yanıtını vermiştir. Tüm maddelerde öğrenenlerin yaklaşık %40'ı katılıyorum yanıtını verirken yaklaşık %10'u da kararsızım yanıtını vermiştir. Bu bulgular değerlendirildiğinde, PDP'ye yönelik genel memnuniyet düzeyinin oldukça yüksek olduğu söylenebilir.

Öğrenenlerin PDP'ye yönelik görüşlerini açık uçlu olarak belirtmelerinin istendiği maddede ise öğrenenler, mesajları ders sorumlusundan almalarının kendilerini motive ettiğini vurgulamışlardır. Rüzgar ve Gözde ders sorumlusundan mesaj almanın kendilerinde olumlu etki yarattığını ve bu uygulamanın yaygınlaştırılmasını istediklerini belirtmişlerdir:

“Performans Değerlendirme Paneli diğer derslerde de kullanılmalı. Sınıfa göre durumumu öğrenmek benim için çok yararlı oldu. Ayrıca sayın Tefrik Hocamın öğrenim sürecimde geri bildirim mesajları yollaması bende itici bir güç yarattı. Kendisine bu konuda çok teşekkür ediyorum. Diğer derslerdeki hocalarımla Tefrik Hoca gibi geri bildirim mesajları paylaşmasını çok isterim. Teşekkürler.” Rüzgar

“Dersin öğretim görevlisinden doğrudan mesaj almak çok etkileyiciydi. Açıköğretim derslerime genelde panel dışından, ders kitapları aracılığıyla çalışmaktayım. Ancak bildirim almak derse katılma isteği uyandırdı. Aktif yüksek lisans öğrencisi olmam nedeniyle derslere katılamamak benim için çok üzücü oldu. Performans değerlendirme paneli umarım tüm derslerde olur.” Gözde

Sezen ise ders sorumlusundan mesaj almanın motivasyonunu yükselttiğini ve kendisini önemli hissettirdiğini ifade etmiştir:

“Bilişim sektöründe 13 yıl tecrübeli bir profesyonel olarak, teknik derslerde çok fazla çalışma ihtiyacı hissetmedim. Ancak buna rağmen, sayın hocamızın gönderdiği mesajlar bana kendimi bir öğrenci olarak önemli ve kıymetli hissettirdi. Motivasyon konusunda kesinlikle çok olumlu etkisi olduğuna inandığım bu uygulaması için kendisine teşekkür etmek ve saygılarımı sunmak isterim.” Sezen

Benzer şekilde Kenan da bu uygulamanın motivasyonunu olumlu yönde etkilediğini dile getirmiştir:

“Panel ve hocamızın yolladığı mesaj motive edici ve çok değerliydi. Canlı dersleri her zaman zamanında takip edemesem de sonradan kayıtları izleyip dersi takip ettim. Emekleriniz için teşekkürler.” Kenan

Gamze ve İpek uygulamayı başarılı bulduklarını, kendileri ile ilgilenildiğini hissettiklerini ve uygulamanın yaygınlaşmasını istediklerini ifade etmişlerdir:

“Çok başarılı bir çalışma, Sayın Tevfik hocamızın bizimle bizzat ilgilendiğini, kişisel olarak takip ettiğini birebir hissettim. Daha çok yaygınlaşması dileğiyle... Saygılarımla...” Gamze

“Diğer dersler içinde olursa gayet güzel olur diye düşünüyorum. Motivasyon arttırmada çok önemli olduğunu düşünmekteyim.” İpek

Benzer şekilde Yusuf, Mehmet ve Rasim de uygulamayı beğendiklerini ve önemsendiklerini hissettiklerini belirtmiştir:

“Panel çok iyi bir uygulama olmuş. Açıköğretim Fakültesi öğrencilerini önemsendiğini kanıtladı. Çok başarılı bir uygulama.” Yusuf

“Birinci sınıfa kayıt yaptırdığımda devam etme konusunda kararsızdım. Bölüm bilgilerini edinebilmeyi hedefim. Bu sebeple en baştan bütün ders kitaplarını satın aldım. Ek olarak epeyce kaynağa da sahibim. Çok zorlansam da bölümümü seviyorum, çalışıyorum. Yine de birinin sizinle ilgilendiğini bilmek değişiklik oldu. Biraz daha fazla çalıştım sanıyorum. Sayın Tevfik Hocama emeklerinden dolayı teşekkür ediyorum.” Mehmet

“Sevgili hocam, ilginiz ve alakanız beni ders çalışmaya teşvik etmek ile beraber beni çok memnun etti. Umarım yüzünüzü kara çıkarmamışımdır. Saygılarımla.” Rasim

Mustafa ve Gülnar ise panelin çalışmalarına destek olduğunu ifade etmişlerdir:

“Gerçekten öğrenme ve çalışma alışkanlığımı olumlu yönde etkiledi.” Mustafa

“Performans Değerlendirme Paneli benim için harika bir yöntemdi ve daha fazla verim almamı sağladı. Çok teşekkür ederim.” Gülnar

Toprak, Ercüment ve Sevinç ise uygulamayı faydalı bulduklarını ancak panelde geliştirme ve düzenlemelerin yapılması gerektiğini düşündüklerini belirtmişlerdir:

“Kesinlikle çok başarılı bir çalışma. Hocamızı canı gönülden kutlarım. Sistemdeki tabloların grafik yapısı (görsel olarak) iyileştirilebilir. Sistemsel hassasiyet biraz daha artırılarak daha keskin ve net olarak, oranlar belli olabilir. Sayın Prof. Dr. Tevfik Volkan YÜZER hocamızı bir kez daha tebrik eder, sistemin diğer derslere de gelmesini önemle rica ederiz.” Toprak

“Kendimi diđerleri ile kıyaslamak hiçbir zaman hoşuma gitmez. Panel kıyaslama yerine yönlendirici olmalı. Emekleriniz için teşekkürler. Çabalarınızın olumlu sonuçlar vermesi dileđiyle. Her zaman irtibata geçebilirsiniz.” Ercüment

“Kesinlikle kullanışlı ve yararlı fakat durumum hakkında fikir edinmekten daha ileriye gidemiyor. Mutlak sonuçlardan ziyade yüzeysel fikirler veriyor. Yine de söylemem gerekir ki keşke diđer tüm derslerde de olsa. Emeđiniz için teşekkürler.” Sevinç

Emre ise böyle bir uygulamaya ihtiyaç duymadığını dile getirmiştir:

“Benim için gereksiz. Kendi programımla ilerletiyorum çalışmalarımı.” Emre

Ankete verilen yanıtlar incelendiđinde öğrenenlerin PDP’ye yönelik görüşlerinin genel olarak olumlu olduđu ve ders sorumlusu ile etkileşim kurmalarının motivasyonlarının yükselmesine katkı sağladığı belirtilebilir.

5. SONUÇ, TARTIŞMA VE ÖNERİLER

Bu bölümde araştırma sonucunda elde edilen sonuçlar, buna ilişkin tartışmalar ve son olarak önerilere yer verilmektedir.

5.1. Sonuç ve Tartışma

Bu araştırmanın genel amacı, kitlesel açık ve uzaktan öğrenme sisteminde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin ve öğrenen profillerinin belirlenmesi, akademik performanslarına yönelik tahmin modeli geliştirilmesi, öğrenme yönetim sistemine entegre olarak çalışabilen bir PDP tasarlanması ve PDP'nin öğrenme sürecindeki etkilerinin incelenmesidir. Anadolu Üniversitesi Açıköğretim Sisteminde gerçekleştirilmiş olan bu çalışmada, sisteme kayıtlı olan ve Anadolium eKampüs Öğrenme Yönetim Sistemini kullanan öğrenenlere ait verilerden yararlanılmıştır. Çalışmada kullanılan veriler, veri ambarında bir araya getirilmiştir. Çalışmanın veri ambarı, Öğrenci Bilgi Sistemi ve Öğrenme Yönetim Sistemi veritabanlarından beslenmektedir. Bu kapsamda çalışmada, öğrenenlerin demografik özellikleri, akademik başarı notları, öğrenme yönetim sistemindeki öğrenme ve gezinme davranışlarından elde edilen veriler ve anket verileri kullanılmıştır. Çalışma tanımlayıcı, tahmin edici ve normatif analitik olmak üzere 3 aşamada gerçekleştirilmiştir. Buna ek olarak, PDP uygulamasında deney tasarımı gerçekleştirilmiş ve PDP sadece deney grubundaki öğrenenlere sunulmuştur. PDP'nin uygulamasında öğrenme ortamı kontrol altına alınmıştır. Bu deney tasarımında, kontrol edilebilir öğrenme ortamları dışında kalan değişkenler göz ardı edilmiştir. Bu araştırmanın her aşamasında farklı çalışma kümeleri ile çalışılmıştır. Tanımlayıcı ve tahmin edici analitik aşamasındaki çalışmalar, 2019-2020 öğretim yılı Güz döneminde, normatif analitik aşamasındaki çalışmalar ise 2020-2021 öğretim yılı Bahar döneminde gerçekleştirilmiştir. Bu çalışma sonucunda elde edilen modeller; belirtilen yıl, dönem, çalışmaya katılan öğrenenler ve çalışmada yer alan dersler ile sınırlıdır. Çalışmada, öğrenme malzemesine erişen öğrenenlerin bu öğrenme malzemelerini öğrenme süreçlerinde kullandıkları kabul edilmiştir. Anadolium eKampüs Sisteminde oturum açık kaldığı sürece öğrenenlerin öğrenme etkinlikleri gerçekleştirdikleri varsayılmıştır.

Sonuç ve tartışma bölümü, çalışmanın araştırma soruları bağlamında ele alınmıştır.

5.1.1. Çevrimiçi öğrenme ortamında öğrenenlerin davranış örüntülerinin belirlenmesi

Bu aşamada, “Araştırma Sorusu 1: Kitlesele açık ve uzaktan öğrenme sisteminde öğrenenlerin e-öğrenme ortamı kullanım davranışlarında hangi örüntüler bulunmaktadır?” sorusuna yanıt aranmıştır. Öğrenenlerin çevrimiçi öğrenme ortamındaki davranış örüntülerinin ortaya çıkarılması amacıyla öğrenenlerin zaman bazlı öğrenme malzemeleri kullanım verileri analiz edilmiştir. Örüntülerin belirlenmesi çalışması, 2019-2020 öğretim yılı Güz döneminde, 86 farklı programa kayıtlı olan 602.372 öğrenene ait veriler analiz edilerek gerçekleştirilmiştir. Örüntülerin belirlenmesi için Apriori, CARMA ve FP-Growth algoritmaları kullanılmıştır.

Örüntülerin belirlenmesinden önce öğrenenlerin sistem kullanım alışkanlıkları incelenmiştir. Bunun için 2019-2020 öğretim yılı Güz dönemi 30 Eylül 2019-20 Ocak 2020 tarihleri arasında 602.372 öğrenene ait 7.115.874 oturum ve 48.990.340 etkinlik analiz edilmiştir. Yapılan analizler sonrasında öğrenenlerin çoğunlukla deneme sınavı, ünite özeti ve çıkmış sınav soruları malzemelerini kullanmayı tercih ettikleri belirlenmiştir. AÖS’teki öğrenenlerin daha çok soru tabanlı öğrenme malzemelerini kullandıkları görülmektedir. Bu sonucun AÖS’teki ölçme değerlendirme sistemiyle ilişkili olduğu söylenebilir. AÖS’te sınavlar, çoktan seçmeli sorulardan oluşmaktadır. Bu nedenle öğrenenler, soru tabanlı malzemeleri sınava hazırlanmak için daha fazla tercih etmiş olabilirler. Bununla birlikte, öğrenenlerin yaşları yükseldiğinde deneme sınavı kullanımında artış olduğu gözlenmiştir. Öğrenenlerin yaş gruplarına göre en yüksek ortalama erişim 42 yaş ve üstü, en düşük erişim ise 25 yaş ve altı grupta ortaya çıkmıştır. 25 yaş ve altındaki öğrenenlerin hem dijital yeterliliklerinin 42 yaş üstündeki öğrenenlere göre görece daha yüksek hem de çoğunlukla ilk defa üniversite öğrencisi olmaları göz önüne alındığında erişimlerinin daha yüksek olması beklenebilir. Ancak analiz sonuçlarında bunun tersi bir durum ortaya çıkmıştır. Bu durum cinsiyetler açısından incelendiğinde ise, kadın öğrenenlerin erkeklerden daha çok malzemelere eriştikleri belirlenmiştir. Kayıt türlerine göre malzeme erişimleri incelendiğinde, İkinci Üniversite kapsamında kayıt yaptıran öğrenenlerin öğrenme malzemeleri toplam ve ortalama erişimlerinin diğer kayıt türlerindeki öğrenenlerden daha yüksek olduğu belirlenmiştir. İkinci Üniversite öğrenenleri halen bir lisans programında eğitimlerine devam eden ya da mezun durumundaki öğrenenlerdir. Bu öğrenenlerin hem

üniversite eğitimi deneyimlerinin olması hem de bölümlerini seçerken daha bilinçli tercihler yapmış olmaları varsayılabileceğinden dolayı bu durum beklenen bir sonuç olarak yorumlanabilir.

Öğrenme malzemeleri erişimi genel not ortalamaları bağlamında değerlendirildiğinde en yüksek ortalama erişim ise 3,00-4,00, en düşük erişimler ise 0,00-0,99 not aralığında ortaya çıkmıştır. Öğrenme malzemeleri ile daha çok etkileşime giren öğrenenlerin daha yüksek not ortalamasına sahip olması beklenen bir sonuçtur. Benzer bir sonuç, Ziebarth vd. (2015) tarafından yapılan çalışmada da elde edilmiştir. Buna ek olarak 3,00-4,00 not aralığında deneme sınavı erişiminin diğer grupların neredeyse 2 katı olduğu belirlenmiştir. Bu farklılığın nedenlerinin farklı veri kaynakları dahil edilerek araştırılması önerilebilir.

Öğrenme malzemelerine erişimler tarih bazlı değerlendirildiğinde en yüksek erişimler ara sınav ve dönem sonu sınavı öncesinde ortaya çıkmıştır. Özellikle ara sınav öncesindeki hafta en yüksek erişim sayılarına erişilmiştir. Hung ve Zhang (2008) da çalışmalarında öğrenenlerin ilk hafta ve proje görevlerini tamamladıkları hafta en fazla oturum açtıklarını belirtmiştir. Bu durum farklı kültürlerdeki öğrenenlerin de sınav ya da proje tarihinden önce çalışmaya daha fazla zaman ayırdıkları şeklinde yorumlanabilir. Ekim ve Kasım aylarında ünite özetlerinin, sınav dönemleri olan Aralık ve Ocak aylarında ise çıkmış sınav soruları ve deneme sınavı erişimlerinin yüksek olduğu belirlenmiştir. Bu bulgular değerlendirildiğinde, sınav dönemlerinde öğrenenlerin soru tabanlı malzemelere yöneldikleri söylenebilir. Öğrenenlerin öğrenme davranışlarındaki örüntüler, ara sınav dönemiyle birlikte değişmektedir. Dönem başından ara sınava kadar olan süreçte öğrenenlerin farklı malzeme türlerini kullanma eğiliminde oldukları ancak sonrasında daha çok sınav odaklı çalıştıkları gözlenmiştir. Öğrenenlerin sınav döneminde özellikle deneme sınavı kullanımlarındaki artış göz önüne alındığında deneme sınavlarının öğrenenlerin öğrenmelerine destek olacak konu ile ilgili kısa bilgilerin yer aldığı etkileşimli bir yapıya dönüştürülmesi önerilebilir. Bunlara ek olarak, sınav dönemleri dışındaki çalışma alışkanlıklarının desteklenmesi için farklı yöntemler geliştirilmesi önerilebilir. Öğrenenlerin sınav dönemi öncesinde de malzeme erişimlerinin yükseltilmesi için motivasyonlarını artırmaya ve çalışma stratejisi geliştirmelerine yönelik uygulamalar geliştirilebilir. Bunun için geri bildirim mesajları ya da yapay zeka tabanlı sanal öğretim asistanları gibi uygulamalar değerlendirilebilir.

Öğrenenlerin malzeme erişimleri gün bazlı değerlendirildiğinde hem toplam hem de ortalama erişim en fazla Cuma ve Pazartesi, en az erişim ise hafta sonu günlerinde gözlenmiştir. Buna ek olarak, Pazartesi gününden itibaren hafta boyunca erişim sayılarında düşüş olduğu belirlenmiştir. Hung ve Zhang (2008) ise çalışmalarında, bu bulgudan farklı olarak haftalık görevlerin başladığı Salı günü öğrenenlerin sistem erişimlerinin yükseldiğini, en az girişin ise Cuma ve Cumartesi günleri olduğunu belirtmişlerdir. AÖS'te sınavlar, Cumartesi ve Pazar günleri gerçekleştirilmektedir. Cuma günü gözlenen yükselişin nedeni sınavlardan önceki yüksek erişim oranları ile açıklanabilir. Hafta boyunca düşüş yaşanması, öğrenenlerin hafta içinde çalışmaya yönelik motivasyon kaybı yaşadığı şeklinde yorumlanabilir. Motivasyon yükseltmeye yönelik çalışmaların yapılmasının öğrenenlerin katılımına destek olabileceği düşünülmektedir. Öğrenenlerin genel olarak öğleden sonra çalışma etkinliklerinin arttığı görülmektedir. Bu durum göz önüne alındığında, önemli bilgilendirme ve mesajların daha çok öğrenene ulaşmasını sağlamak için bu saatlerde gönderilmesi önerilmektedir. AÖS'te çalışan ve ikinci üniversite olarak eğitim alan öğrenen sayısı oldukça fazladır. Bu durum göz önüne alındığında, öğrenenlerin gündüz saatleri yerine akşam saatlerinde daha çok kullanım göstermeleri beklenebilir. Ancak bulgular, bu varsayımın tersine bir sonucu işaret etmektedir. Akşam saatlerindeki kullanımları artırmak için ilgili saatlerde öğrenenlerin dikkatini çekecek etkileşimli etkinliklere yoğunlaşılabilir ve öğrenenlere akşam saatlerinde çalışma alışkanlığı oluşturabilmek için bilgilendirme mesajları ve davet mesajları gönderilebilir. Benzer öneri, alanyazındaki birçok farklı çalışmada da belirtilmektedir (Bañeres vd., 2020; Corrin ve De Barba, 2015; Karaoglan Yılmaz ve Yılmaz, 2021; Kim vd., 2016).

Öğrenenlerin ÖYS ve öğrenme malzemeleri kullanım davranışlarına yönelik genel durum, betimsel istatistiklerle değerlendirildikten sonra birliktelik kuralları algoritmaları kullanılarak öğrenenlerin öğrenme malzeme erişim örüntüleri belirlenmiştir. Destek değeri %20 ve güven değeri %85 olmak üzere Apriori algoritmasıyla 33, CARMA ve FP-Growth algoritmaları ile 25 kural elde edilmiştir. Tüm algoritmalar ile geliştirilen modellerdeki birliktelik kuralları benzer olmakla birlikte aynı güven ve destek değerlerinde Apriori'nin diğer algoritmalara göre daha fazla kural oluşturduğu görülmüştür. CARMA ve FP-Growth algoritmaları ile aynı kurallar elde edilmiştir. Bu farklılığın algoritmaların kural çıkarma süreçlerinin farklı olmasından kaynaklandığı söylenebilir. Destek değeri en yüksek olan yani

tüm kullanımlar içerisinde en sık yer alan kural; Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti kuralıdır. Güven değeri en yüksek olan kural; Deneme Sınavı, Ünite Metni ⇒ Çıkmış Sınav Soruları kuralıdır. Lift değeri en yüksek olan kural ise Deneme Sınavı, Ünite Metni, Çıkmış Sınav Soruları ⇒ Ünite Özeti olarak belirlenmiştir. Güven ve destek değerlerine göre yapılan sıralamalardan farklı olarak lift değerine göre yapılan sıralamada en yüksek 3 değere ait kuralın sonuç alanında Ünite Özeti yer almaktadır. Bu bulgular değerlendirildiğinde; kuralların sonuçlarında çıkmış sınav soruları ve ünite özeti yer aldığı görülmektedir. Benzer şekilde Ozturk ve Kumtepe (2019), çalışmalarında elde ettikleri birliktelik kurallarının çıktılarında çoğunlukla ünite özeti kullanımının yer aldığını ifade etmişlerdir. Bunun yanı sıra, ünite özeti, ünite metni, çıkmış sınav soruları, ders kitabı ve video malzemeleri arasındaki bağlantıların diğer öğrenme malzemeleri arasındaki bağlantılardan daha güçlü olduğu belirlenmiştir. Bu durum, öğrenenlerin çalışmalarında bu öğrenme malzemelerini birlikte kullanma eğiliminde olduğunu göstermektedir. Cruz-Benito vd. (2015) ise sanal öğrenme ortamında daha çok zaman geçiren öğrenenlerin 3 boyutlu öğeler içeren öğrenme nesnelileriyle daha fazla etkileşime girdiklerini ifade etmişlerdir. Graf vd. (2010), farklı öğrenme stiline sahip olan öğrenenlerin derste farklı gezinme davranışları gösterdiklerini vurgulamışlardır. Bu çalışmadan farklı olarak Tlili vd. (2021), öğrenenlerin genel sistem kullanım davranışlarına odaklanmışlar ve ders modülü görüntüleme, ders modülü tamamlama, ödev forumu görüntüleme, ödev yükleme, tartışma forumu görüntüleme ve forumdaki mesajları görüntüleyen diğer öğrenenlerin listelenmesi davranışlarının en sık olarak görülen çevrimiçi davranışlar olduğunu belirlemişlerdir.

Öğrenme malzemeleri erişim örüntüleri not ortalamaları bağlamında değerlendirildiğinde genel not ortalaması yüksek olan öğrenenlerin deneme sınavı, ünite metni ve çıkmış sınav sorularını birlikte kullanma eğilimlerinin yüksek olduğu belirlenmiştir. Çalışmada öğrenenlerin oturum açtıkları ilk hafta bağlamında birliktelik kuralları ara sınav öncesi, ara sınav dönemi ve ara sınav sonrası olarak incelenmiştir. Ara sınav öncesinde öğrenenlerin farklı öğrenme malzeme türlerini birlikte kullandıkları görülmüştür. Bu durum öğrenenlerin ara sınav öncesinde farklı öğrenme malzemeleri ile çalışmalarına devam etmeleri ya da öğrenme malzemelerini incelemek istemeleri şeklinde yorumlanabilir. Ara sınav döneminde ise deneme sınavı, ünite özeti, ünite metni ve çıkmış sınav soruları kullanımına yönelim olduğu belirlenmiştir. Ara sınav sonrasında, ara sınav dönemine benzer

örüntüler görülmüştür. Benzer şekilde Ziebarth vd. (2015) çalışmalarında, sınava hazırlık aşamasında öğrenenlerin ortak örüntüler gösterdiklerini ortaya koymuştur.

Öğrenme malzemelerinin etkileşim unsurlarıyla zenginleştirilmesi öğrenen-içerik etkileşiminin artmasına olanak sunarak öğrenme sürecine katkı sağlayabilir. Bunun yanı sıra, öğrenenlere deneme sınavları ve alıştırma sınavlarında yanlış yaptıkları sorular ya da çalışmadıkları üniteler göz önüne alınarak kazanım odaklı geri bildirimler ya da ilerleme raporları sunulabilir. Bu geri bildirimlerin, öz yönelimli öğrenenlerin kendi performanslarını değerlendirerek yeni stratejiler geliştirmelerine olanak sağlayacağı düşünülmektedir.

Öğrenenlerin öğrenme malzemelerinden daha çok çıkmış sınav sorularını kullanmaları öğrenme süreci açısından bir sorun durumu olarak değerlendirilebilir. Bu problemin olası çözümleri olarak Christoforou ve Yigit (2008), Holmes (2018) ve Hernández'in (2012) de çalışmalarında belirttikleri gibi sürekli değerlendirmeye geçilmesi; projeler, ödevler ve görevlerin sürece dahil edilmesi ve etkinlik tabanlı tasarımların kullanılması önerilebilir.

5.1.2. Çevrimiçi öğrenme ortamında öğrenen profillerinin belirlenmesi

Bu aşamada, "Araştırma Sorusu 2: Kitlesele açık ve uzaktan öğrenme sisteminde öğrenenlerin demografik özellikleri, e-öğrenme ortamı kullanım davranışları ve akademik performansları kullanılarak öğrenen profilleri oluşturulabilir mi?" sorusuna ve bu soruyla ilgili alt araştırma sorularına yanıt aranmıştır. Araştırma Sorusu 2'ye ait alt araştırma soruları aşağıda verilmiştir:

- 2.1. Öğrenen profillerinin oluşturulmasında en ayırt edici değişkenler hangileridir?
- 2.2. Öğrenen profillerinin oluşturulması için kullanılabilen en başarılı algoritmalar hangileridir?

Öğrenen profillerinin belirlenmesi için 2019-2020 öğretim yılı Güz döneminde kayıtlı olan 597.164 öğrenene ait veriler analiz edilmiştir. Profillerin belirlenmesinde kümeleme analizi algoritmalarından TwoStep ve k-Means algoritmaları kullanılmıştır. TwoStep algoritması hiyerarşik, k-Means algoritması ise bölümlenmeli bir kümeleme algoritmasıdır. Bu algoritmalar, araştırmadaki veri türleri ile çalışabildikleri ve birbirlerinden farklı yöntemlerle kümeleri oluşturdukları için tercih edilmiştir. Öğrenen profillerinin belirlenmesi

için kümeleme kalitesinin artırılması hedeflenerek deneysel ve yinelemeli bir süreç gerçekleştirilmiştir.

Birinci alt araştırma sorusu kapsamında öncelikle öğrenen profillerinin oluşturulmasındaki en ayırt edici değişkenler incelenmiştir. Bu değişkenlerin kullanılan algoritmaya göre farklılaştığı belirlenmiştir. TwoStep algoritmasında; Çıkmış Sınav Soruları Erişim Sayısı, Deneme Sınavı Erişim Sayısı, Ders Kitabı Erişim Sayısı, Dönem Sonu Ortalama Puan, Oturum Açılan Gün Sayısı, Oturum Sayısı, Sınava Girme Oranı, Toplam Faaliyet Süresi (dk), Ünite Metni Erişim Sayısı, Ünite Özeti Erişim Sayısı, Video Erişim Sayısı ve Yaş Grubu değişkenleri en ayırt edici değişkenler olarak belirlenmiştir. TwoStep ile elde edilen kümelerde öğrenenlerin yaş grubunun kümelerin ayrılmasında büyük etkiye sahip olduğu ortaya çıkmıştır. k-Means algoritmasında ise Çıkmış Sınav Soruları Erişim Sayısı, Deneme Sınavı Erişim Sayısı, Ders Kitabı Erişim Sayısı, Dönem Sonu Ortalama Puan, Günlük Ortalama Oturum Açma Sayısı, İlk Oturum Ayı=11, Kullanılan Malzeme Türü Sayısı, Oturum Açılan Gün Sayısı, Oturum Sayısı, Sınava Girme Oranı, Toplam Faaliyet Sayısı, Toplam Faaliyet Süresi (dk) ve Yaş değişkenleri en ayırt edici değişkenler olarak ortaya çıkmıştır. k-Means algoritması ile elde edilen kümelerde ise dönem sonu ortalama sınav puanı, ilk oturum açılan ay, toplam faaliyet sayısı ve oturum sayısı gibi daha çok öğrenme sürecine yönelik girdiler kümelerin belirlenmesinde etkili olmuştur. Öğrenenlerin demografik özelliklerinin ise kümelerin oluşturulmasında düşük ayırıcılık gücüne sahip oldukları belirlenmiş ve yaş dışındaki öznitelikler analize dahil edilmemiş ancak bunlar kümelerin tanımlanmasında kullanılmışlardır. Elde edilen kümeler incelendiğinde, ayırt ediciliği en yüksek olan değişkenin dönem sonu ortalama puan olduğu belirlenmiştir. Bu çalışmada kullanılan verilere benzer olarak Bouchet vd. (2013), zeki bir öğretim sisteminde yer alan öğrenenleri etkileşimlerine göre gruplandırmışlardır. Yukselturk ve Top (2013) kümelerin belirlenmesinde öğrenenlerin giriş özellikleri ve katılım davranışlarını, Jovanovic vd. (2012) ise öğrenenlerin bilişsel stilleri ve ders notlarını öğrenen profillerinin belirlenmesinde kullanmışlardır. Dwivedi ve Bharadwaj (2015), öğrenenlerin öğrenme stilleri, bilgi düzeyleri ve kullandıkları malzemelere ilişkin değerlendirmelerine; Rezaei ve Montazer (2016) ise öğrenenlerin kişisel özelliklerine, davranışlarına ve öğrenme stillerine göre gruplar oluşturmuşlardır. Bunlardan farklı olarak Amershi ve Conati (2009), öğrenen profillerinin oluşturulmasında arayüz etkileşimi ve göz izleme verilerini kullanmışlardır. Bu

çalışmada kullanılan değişkenlerin farklı sistemlerdeki değişkenler ile karşılaştırılması doğru olmayan değerlendirmelere yol açabilir. Çünkü sistemler dinamikleri, öğrenen özellikleri ve depolanan kayıtlar açısından farklı yapıda olabilirler. Karşılaştırma ve değerlendirme yapılırken bunlara dikkat edilmesi önerilmektedir. Ancak bu çalışmadaki işlem süreçleri ve elde edilen bulgular, yeni araştırmalar için yol haritası sunabilir ve bir başlangıç noktası olabilir.

İkinci alt araştırma sorusu bağlamında farklı algoritmalar ile elde edilen öğrenen profilleri incelenmiştir. Yapılan tekrarlı analizler sonucunda TwoStep algoritması ile 7 küme, k-Means algoritması ile 6 küme elde edilmiştir. Bu çalışmaya benzer olarak Yukselturk ve Top (2013), TwoStep algoritması kullanılarak cinsiyet ve çalışma durumlarına göre isimlendirilen 3 küme elde etmişlerdir. Jovanovic vd. (2012) profillerin belirlenmesi için k-Means algoritması kullanmış ve farklı derslerde farklı öğrenen gruplarının ortaya çıktığını belirtmişlerdir. Bunlardan farklı olarak Bouchet vd. (2013), Beklenti Maksimizasyonu algoritması kullanarak kümeleme analizi gerçekleştirmiş ve 3 öğrenen profili elde etmişlerdir. Hogo (2010), e-öğrenenlerin davranışlarını değerlendirmek için bulanık kümeleme c-means ve çekirdek bulanık c-means gibi bulanık kümeleme yöntemlerini, Rezaei ve Montazer (2016) ise 4 adımlı kümeleme gerçekleştirmiş ve farklı algoritmaları birlikte kullanmışlardır. Bunun yanı sıra, Premlatha vd. (2016), uyarlanabilir e-öğrenme ortamındaki öğrenenlerin değişen tercihlerine ve gereksinimlerine göre güncellenen dinamik bir öğrenen profillemesi sunmuşlardır. Çalışmada öğrenenler öğrenme türlerine göre çalışan ve başarılı öğrenenler, düzenli çalışan ve zeki öğrenenler, yavaş öğrenenler ve az çalışan öğrenenler olmak üzere 4 sınıfta incelenmişlerdir. Amershi ve Conati (2009) ise profilleri belirlemek için geliştirdikleri çevrimiçi k-Means sınıflandırıcısını kullanmışlardır. Bu sınıflandırıcı ile sisteme yeni giren bir öğrenenin sınıfı, öğrenme ortamı ile etkileşimine bağlı olarak, kademeli olarak güncellenmiştir.

Bu çalışmada, TwoStep ve k-Means algoritması ile gerçekleştirilen analizler sonucunda en düşük dönem sonu ortalama puanına sahip kümeler benzer özellikler gösterdikleri için aynı isim altında gruplandırılmışlardır. Bu işlemin ardından her iki analiz sonucunda da Yüksek Puan Grubu, Yüksek Erişim Grubu, Ortalama Üstü Puan Grubu, Ortalama Altı Puan Grubu ve Düşük Puan Grubu olmak üzere 5 grup oluşturulmuştur. TwoStep ile elde edilen kümelerle düşük puanlara sahip gruplara ait bilgi edinilmiş ancak

yüksek puan grupları hakkında çok fazla bilgi edinilememiştir. Her iki algoritma ile elde edilen kümeler incelendiğinde k-Means ile elde edilen kümelerin Açıköğretim Sistemindeki öğrenenlere yönelik daha fazla bilgi sunduğu görülmüş ve çalışmada bu kümelerin özellikleri değerlendirilmiştir.

Öğrenen sayısının en fazla olduğu küme, Ortalama Altı Puan grubudur. Bu gruptaki öğrenenlerin genç ve yarıdan fazlasının çalışan öğrenenlerden oluştuğu söylenebilir. Bu öğrenenlerin dönem sonu ortalama puanları 30 ve sınava girme oranları yüksektir. Bu grup, tüm kümeler arasında en düşük erişime sahip gruptur. Öğrenen sayısı açısından en büyük ikinci grup, Yüksek Erişim Grubudur. Bu gruptaki yaş grubu dağılımlarının birbirine yakın olduğu ve kadın oranının erkeklerden daha fazla olduğu görülmüştür. Dönem sonu ortalama puanları 47 ve sınava girme oranları yüksek olan bu gruptaki öğrenenlerin yarıdan fazlası çalışmaktadır. Öğrenen sayısı açısından 3. sıradaki grup, Düşük Puan grubudur. Bu gruptaki öğrenenlerin yaş ortalamalarının diğer kümelerden düşük olduğu ve yarıdan fazlasının çalışan öğrenenlerden oluştuğu söylenebilir. Çalışan öğrenen oranı, bu kümede diğerlerinden daha yüksektir. Bu öğrenenlerin dönem sonu ortalama puanları 5 ve sınava girme oranları oldukça düşüktür. Öğrenen sayısı açısından 4. sıradaki grup, Yüksek Puan grubudur. Bu gruptaki öğrenenlerin yaş ortalamalarının diğer kümelerden yüksek olduğu ve yarıdan fazlasının çalışan öğrenenlerden oluştuğu söylenebilir. Bu öğrenenlerin dönem sonu ortalama puanları 61'dir ve sınava girme oranları yüksektir. Öğrenen sayısı açısından 5. sıradaki grup ise Ortalama Üstü Puan grubudur. Bu gruptaki yaş grubu dağılımlarının birbirine yakın olduğu ve kadın oranının erkeklerden daha fazla olduğu görülmüştür. Dönem sonu ortalama puanları 43 ve sınava girme oranları yüksek olan bu gruptaki öğrenenlerin yarıdan fazlası çalışmaktadır.

Grupların ortalama sınav puanları incelendiğinde tüm gruplarda ara sınav notlarının dönem sonu sınavlarına göre daha yüksek olduğu görülmektedir. Sistem kullanımları açısından değerlendirildiğinde Yüksek Erişim grubunun diğerlerinden farklılaştığı belirlenmiştir. Bununla birlikte, Yüksek Puan grubundaki öğrenenlerin sistem kullanımlarının beklenenden düşük olduğu söylenebilir. Bu kümedeki öğrenenler, öğrenme malzemelerini indirdikten sonra çalışmalarına çevrimdışı olarak devam etmeyi tercih etmiş olabilirler. Hung ve Crooks (2009) tarafından yapılan çalışmada ise bu bulgudan farklı olarak en yüksek puan değerine sahip kümedeki öğrenenlerin diğer kümelerdekilere göre daha

yüksek katılım gösterdikleri bulunmuştur. Gruplarda genellikle en çok ünite özeti ve çıkmış sınav soruları kullanımı görülmekle birlikte Yüksek Erişim grubunda en yüksek kullanım deneme sınavında ortaya çıkmıştır. En düşük kullanımlar ise video ve ders kitabı malzemelerinde gözlenmiştir.

Düşük Puan grubundaki öğrenenlerin puan ortalamalarının oldukça düşük olduğu belirlenmiştir. Bu gruptaki öğrenenlerin puanlarının düşük olmasının nedenlerinden biri, bu öğrenenlerin sınava girme oranlarının da düşük olması olabilir. Bunun yanı sıra, bu grupta çalışan öğrenen oranı diğer kümelerden daha yüksek ve öğrenenlerin yaş ortalaması diğer kümelerden daha düşüktür. Bu gruptaki öğrenenlerin çalışma durumlarından dolayı sistem kullanımlarının ve sınava girme oranlarının düşük olduğu değerlendirilebilir. Buna ek olarak, öğrenenlerin ara sınavdan düşük not aldıklarında final sınavına girmedikleri ve sistem kullanımlarının azaldığı görülmüştür. AÖS'te öğrenen performanslarının sadece 2 sınavla değerlendiriliyor olması bu duruma neden olmuş olabilir. Öğrenenler ilk sınavdan başarısız olduklarında diğer sınavdan da başarısız olacaklarını ya da diğer sınavdan alacakları puanın geçmeleri için yeterli olmayacağını değerlendirip sınava girmekten vazgeçmiş olabilirler. Bu gruptaki öğrenenlerin sınavlara girmelerini ve sisteme devam etmelerini sağlamak için sürekli değerlendirmeye geçilmesi ve sınavlar ağırlıklarının düzenlenmesi önerilebilir. Buna ek olarak, bu gruptaki öğrenenler çalışma durumlarından dolayı sınavlara girme zamanları konusunda da sorun yaşamış olabilirler. Öğrenenlerin sınavlara kendi tercih ettikleri zaman aralıklarında girmelerine yönelik esneklik sağlanması, bu gruptaki öğrenenlerin sınava girme oranlarının yükseltilmesine olanak sağlayabilir. Çalışma şartlarının ağır olması, öğrenme süreci için gerekli zaman ayıramamak ve ölçme değerlendirme etkinliklerine katılamamak; öğrenenlerin uzaktan eğitilden ayrılma nedenlerine örnek verilebilir (Willging ve Johnson, 2009). Düşük Puan grubundaki öğrenenlerin puanları ve sınava girme durumları göz önüne alındığında, bu öğrenenlerin sistemden ayrılma olasılıklarının yüksek olduğu değerlendirilebilir. Öğrenenlerin ÖYS'deki hareketleri ve çalışma alışkanlıkları incelenerek öğrenenlerin sistemden ayrılma durumları erken dönemlerde belirlenebilir ve erken müdahale uygulamaları gerçekleştirilebilir (Mubarak vd., 2020). Bu bağlamda, bu araştırma kapsamında geliştirilen davranış örüntüleri, öğrenen profilleri ve akademik performans tahmin modeli çalışmaları birlikte kullanılarak sistemden ayrılma oranlarının azaltılmasına yönelik çalışmalar gerçekleştirilebilir.

Premlatha vd. (2016), öğrenenlerin değişen tercihlerine ve gereksinimlerine göre güncellenen dinamik öğrenen profillemesi yaklaşımının bir dersi tamamlamak için daha motive edici olduğunu belirtmişlerdir. Bu bağlamda, Anadolu eKampüs'ün gerçek zamanlı veri analizine uygun bir altyapıya sahip olması üzerinde çalışmaların yapılması önerilmektedir. Bunun yanı sıra, öğrenenlerin öğrenme malzemelerine eriştikten sonra öğrenme malzemesi ile etkileşimlerine yönelik veriler bulunmamaktadır. Öğrenen-içerik etkileşimine yönelik verilerin erişim düzeyinin ötesinde etkileşim düzeyine yönelik olması, öğrenme sürecine yönelik daha detaylı bilgilere ulaşılmasına olanak sağlayabilir. Öğrenenlerin malzeme üzerindeki tüm hareketlerinin, etkileşimlerinin ve bu sayede öğrenme sürecinin kayıt altına alınabildiği izleme ve değerlendirme araçlarının kullanılması ve buna uygun öğrenme malzemeleri türlerinin geliştirilmesi önerilebilir. Bu geliştirme, öğrenenlerin çalışma alışkanlıklarının daha detaylı olarak analiz edilmesine olanak sağlayabilir ve bu sayede çalışma alışkanlıklarına göre öğrenen profilleri oluşturulabilir. Bunlara ek olarak, profillerin yorumlanması ve öğrenenlerin daha iyi anlaşılabilmesi için öğrenenlerin kayıt amaçlarına, motivasyon ve hedeflerine yönelik araştırmaların yapılmasının önemi vurgulanabilir.

5.1.3. Akademik performans tahmin modelinin geliştirilmesi

Bu aşamada, “Araştırma Sorusu 3: Kitlesele açık ve uzaktan öğrenme sisteminde öğrenenlerin e-öğrenme ortamındaki etkileşimleri kullanılarak öğrenenlerin akademik performansı tahmin edilebilir mi?” sorusuna ve bu soruyla ilgili alt araştırma sorularına yanıt aranmıştır. Araştırma Sorusu 3'e ait alt araştırma soruları aşağıda verilmiştir:

- 3.1. Öğrenenlerin akademik performans tahmin modelinin oluşturulmasında en yüksek tahmin gücüne sahip değişkenler hangileridir?
- 3.2. Öğrenenlerin akademik performansının tahmin edilmesi için doğruluk oranı en yüksek algoritmalar hangileridir?

Öğrenenlerin akademik performanslarının tahmin edilmesi çalışması, 2019-2020 öğretim yılı Güz döneminde BIL101U dersinde gerçekleştirilmiştir. Tahmin modelinin geliştirilmesi çalışması, BIL101U dersine kayıtlı 56.810 öğrenene ait veriler analiz edilerek

gerçekleştirilmiştir. Tahmin modelinin geliştirilmesi amacıyla öğrenenlerin malzeme kullanım verileri, demografik özellikleri, bölümleri ve sınav notları verileri kullanılmıştır.

Tahmin modelinin geliştirilmesi için Gradient Boosted Trees (GBT), Deep Learning (DL), Random Forest (RF), Logistic Regression (LR), Decision Tree (DT), Fast Large Margin (FLM), Generalized Linear Model (GLM) ve Naive Bayes (NB) olmak üzere 8 farklı algoritma ile analiz yapılmıştır. Birinci alt araştırma sorusu kapsamında öncelikle öğrenenlerin akademik performans tahmin modelinin oluşturulmasında en yüksek tahmin gücüne sahip değişkenler incelenmiştir. Bu değişkenlerin algoritmalar bağlamında farklılaştığı belirlenmiştir. En az değişken LR, en fazla değişken ise GLM algoritmasında kullanılmıştır. Yapılan analizlerde tahmin modellerinin oluşturulmasındaki kullanılan değişken sayılarının 7 ile 24 arasında değiştiği ve bunların en önemlilerinin ara sınav puanı ve sınava girme oranı olduğu belirlenmiştir. Sadece bu iki değişken kullanılarak daha yüksek değişken sayısı ile elde edilen tahmin doğruluğuna yakın sonuçlar elde edilmiştir.

Gašević vd. (2016), Zacharis (2015), Cerezo vd. (2016), Zafra vd. (2011) ve Romero, Espejo vd. (2013) tarafından yapılan çalışmalarda kullanılan değişkenlerin bu çalışma ile benzerlikler gösterdiği belirlenmiştir. Gašević vd. (2016), öğrenenlerin Moodle ÖYS'den elde edilen kullanım verilerini ve öğrenci bilgi sisteminde yer alan verilerini analiz etmiş ve tahmin için çoklu lineer regresyon kullanmışlardır. Benzer şekilde Zacharis (2015) de çalışmasında öğrenen performansını tahmin etmek için regresyon analizi yapmış; mesaj gönderme ve okuma sayısı, içerik oluşturmaya katkı, sınavlardan alınan puanlar ve görüntülenen içerik sayısının öğrenenlerin final notundaki varyansın %52'sini tahmin edebildiğini belirlemiştir. Cerezo vd. (2016), final puanları ile en yüksek ilişki düzeyine sahip değişkenleri görevler için harcanan süre, görevi tamamlamak için geçen gün sayısı ve forum gönderilerinde kullanılan kelime sayısı olarak belirtmiştir. Zafra vd. (2011) ise çalışmalarında çoklu örnekle öğrenme yöntemini kullanmışlardır. Çalışmada öğrenenlerin tamamladıkları ödevler ve bu görevler için geçirdikleri süre, forumlarda okudukları ve gönderdikleri mesaj sayısı ve süre, görüntüledikleri, başarılı ve başarısız oldukları sınav sayısı ve süre değişkenleri kullanılmıştır. En iyi tahmin %73,57 doğruluk ile PART algoritması ile elde edilmiştir. Romero, Espejo vd. (2013) çalışmalarında, öğrenen performansını tahmin etmek için farklı algoritmaları test etmişler ve tamamlanan ödev sayısı, başarılı ve başarısız olunan sınav sayıları, forumlarda gönderilen ve okunan mesaj sayısı,

sınav ve forumlarda harcanan toplam süre özniteliklerini girdi, final notu özniteliğini ise sınıflandırıcı olarak kullanmışlardır. Çalışmada, %65 tahmin doğruluğuna ulaşılmış ve öğrenenlerin kullanım verilerinden yola çıkarak final notlarını tahmin etmenin çok zor bir görev olduğunu vurgulanmıştır.

Aybek ve Okur (2016), Anadolu Üniversitesi Açıköğretim Sisteminde Temel Bilgi Teknolojileri I dersindeki öğrenenlerin akademik performanslarını tahmin etmek için yapay sinir ağları kullanmışlardır. Yapılan analizler sonucunda, ara sınav notunun final notunun en önemli yordayıcısı olduğu, çoğu demografik değişkenin ise tahmin etme gücünün yüksek olmadığını belirlemişlerdir. Bu bulgular, araştırma kapsamında elde edilen bulgularla benzerlik göstermekle birlikte çalışmada geçme-kalma durumlarının tahmin edilmesi bağlamında farklılıklar belirlenmiştir. Bu çalışmadan elde edilen bulgulara paralel olarak Kotsiantis vd. (2010) tarafından tek bir makine öğrenmesi algoritması kullanmak yerine Naive Bayes, 1-NN ve WINNOW algoritmalarını birleştiren bir çevrimiçi topluluk algoritması önerilmiştir. Bu algoritma ile öğrenenlerin demografik verilerine dayanan ilk tahminlerde %73 tahmin doğruluğuna, bu verilere yazılı ödev notları da dahil edilerek final sınavı öncesinde ise %82 tahmin doğruluğuna ulaşılmıştır.

İkinci alt araştırma sorusu bağlamında farklı algoritmalar ile elde edilen akademik performans tahmin modelleri karşılaştırılmıştır. En yüksek tahmin doğrulukları, GBT (%72,16) ve DL (%72,01) algoritmaları ile elde edilmiştir. Bunu RF (%70,8), LR (%70,1), DT (%69,9), FLM (%69,8) ve GLM (%69,7) algoritmaları izlemiştir. En düşük tahmin doğruluğu ise NB algoritması (%64,4) ile elde edilmiştir. AÖS verileri ile akademik tahmin modelinin geliştirilmesinde ağaç tabanlı algoritmalar ve derin sinir ağları en iyi sınıflayıcılar, Bayes tabanlı algoritma ise en düşük tahmin doğruluğunu veren sınıflayıcı olarak belirlenmiştir. Algoritmaların F harf notunu yani dersten kalan öğrenenleri başarılı bir şekilde tahmin ettikleri ancak A ve D harf notlarını tahmin etmede başarısız oldukları görülmüştür. Çalışmada, GBT algoritması ile en yüksek tahmin doğruluğuna erişildiği için bu algoritma ile edilen tahmin modeli değerlendirilmiştir. GBT algoritması ile elde edilen sonuçlar değerlendirildiğinde, algoritmanın F (%89,53), B (%73,05) ve C (%61,02) harf notlarını tahmin etmede başarılı olduğu söylenebilir. Bu algoritma, A harf notunu %36,10 doğrulukla tahmin ederken D (%3,08) harf notunu ise çok düşük bir doğrulukla tahmin edebilmiştir.

Geliştirilen tahmin modelleri değerlendirildiğinde, başarısız olma ihtimali olan öğrenenlerin sadece ara sınav puanı ve sınava girme oranları kullanılarak bile yüksek doğruluk oranıyla tahmin edildiği görülmüştür. Bu bulgu, ara sınav sonrasında bu çalışmada elde edilen tahmin doğruluğu sonuçlarına yakın doğrulukta tahminler yapılabileceği şeklinde yorumlanabilir. Öğrenenlerin sistem kullanımlarının en yoğun olduğu dönemin ara sınav öncesi göz önüne alındığında ara sınav puanı, sınava girme durumu ve sistem kullanım metrikleri ile tahmin modelleri geliştirilebilir. Diğer bir deyişle, geliştirilen model farklı dönemlerde test edilerek dönem sonu beklenmeden ara sınav sonrasında tahmin sonuçları üreten yeni modeller geliştirilebilir. Bu sayede başarısız olma olasılığı yüksek olan öğrenenlere özel erken uyarı uygulamaları ve geri bildirim mesajları tasarlanabilir.

5.1.4. Öğrenme analitikleri tabanlı performans değerlendirme paneli uygulamasının öğrenme sürecine etkileri

Bu aşamada, “Araştırma Sorusu 4: Kitlesele açık ve uzaktan öğrenme sistemlerinde PDP kullanımının öğrenme sürecine etkileri nelerdir?” sorusuna ve bu soruyla ilgili alt araştırma sorularına yanıt aranmıştır. Araştırma Sorusu 4’e ait alt araştırma soruları aşağıda verilmiştir:

- 4.1. Deney ve kontrol gruplarının ÖYS’de oturum açma sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
- 4.2. Deney ve kontrol gruplarının ÖYS’de oturum açtıkları gün sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
- 4.3. Deney ve kontrol gruplarının öğrenme malzemelerine erişim sayılarında istatistiksel olarak anlamlı bir farklılık var mıdır?
- 4.4. Deney ve kontrol gruplarının akademik performanslarında istatistiksel olarak anlamlı bir farklılık var mıdır?

PDP uygulaması, 2020-2021 öğretim yılı Bahar döneminde BIL102U dersinde gerçekleştirilmiştir. PDP’nin öğrenme sürecindeki etkilerinin belirlenmesi için deneysel bir çalışma yürütülmüş ve uygulama sırasında öğrenenler, seçkisiz olarak deney ve kontrol gruplarına ayrılmıştır. Deney grubuna PDP ve geri bildirimler sunulmuş, kontrol grubuna ise sunulmamıştır. Deney grubunda 13.377, kontrol grubunda ise 13.376 öğrenen bulunmaktadır. Uygulama, 17 hafta boyunca devam etmiştir.

Sistem üzerinden öğrenenlere toplam 78 metin mesajı, 1 video mesajı ve 6 kısa mesaj (SMS) gönderilmiştir. Mesajların ortalama okunma oranı %9 olmakla birlikte pop-up mesajlarda bu oranın daha yüksek olduğu görülmüştür. Bodily vd. (2018) tarafından yapılan çalışmada öğrenenlerin PDP'lere yönelik algılarının olumlu olduğu ancak kullanım düzeylerinin düşük olduğu belirlenmiştir. Bu çalışmada, mesajların okunma bilgisinin elde edilmesi için öğrenenlerin mesajın altında yer alan "Okudum" ifadesine tıklaması gerekmektedir. Bu işlem yapılmadığında mesajlar okunsa da veri alınmamaktadır. Mesaj okunmalarındaki oranın düşük olması, bu durumdan kaynaklanıyor olabilir. Mesajlar amaçlarına uygun olarak farklı zaman aralıklarında sistemde kalmaktadır. İlgili tarih aralığında sisteme giriş yapmayan öğrenenler mesajları görememektedirler. Bu durum da düşük mesaj okunma oranına neden olmuş olabilir. Öğrenenlerin mesajları okuduktan sonra en fazla eriştikleri öğrenme malzemeleri ise sırasıyla kitap, çıkmış sınav soruları, ünite özeti ve canlı ders olarak belirlenmiştir. Öğrenenlerin mesajları okuduktan sonra çoğunlukla kitaba erişmeleri genel malzeme kullanım örüntülerinden farklıdır. Geri bildirim mesajlarının çalışma alışkanlıklarındaki değişim üzerindeki etkisi, farklı araştırmalarla incelenmelidir.

Alt araştırma soruları bağlamında ilgili değişkenler açısından deney ve kontrol grupları arasında istatistiksel olarak anlamlı bir fark olup olmadığının belirlenmesi için bağımsız örneklem t-testi gerçekleştirilmiştir. Yapılan analizler sonucunda deney grubunun açılan oturum sayısı ortalaması, ortalama oturum açılan gün sayısı, ortalama öğrenme malzemeleri erişimi ve dönem sonu ortalama puanı ile kontrol grubunun açılan oturum sayısı ortalaması, ortalama oturum açılan gün sayısı, ortalama öğrenme malzemeleri erişimi ve dönem sonu ortalama puanı arasında istatistiksel olarak anlamlı bir farklılık olduğu belirlenmiştir. Bu değişkenlerin ortalama değerlerinin deney grubundaki öğrenenlerde kontrol grubundaki öğrenenlere göre daha yüksek değerlerde olduğu görülmüştür. Bu sonuçlara paralel olarak Love vd. (2021), yaptıkları çalışmada paneli kullanan öğrenenlerin %66'sının çalışma ve ders etkinliklerini planlama alışkanlıklarında değişim olduğunu; Aljohani vd. (2019) paneli kullanan öğrenenlerin ÖYS'ye ve tartışma panosuna daha sık eriştiklerini ve final notlarının diğerlerinden daha yüksek olduğunu; Kokoç ve Altun (2019) PDP'ler ile etkileşime giren öğrenenlerin akademik başarılarının daha yüksek olduğunu; Jivet (2021) de PDP ile daha fazla etkileşime giren öğrenenlerin mezun olma olasılıklarının daha yüksek olduğunu vurgulamışlardır. Benzer olarak Ulfa vd. (2019), PDP'lerin öz düzenlemeli öğrenmeye

destek olduğunu ve PDP kullanımı ile öğrenenlerin e-öğrenme etkileşimlerinin yükseldiğini; Kim vd. (2016) de PDP aracılığıyla geri bildirim alan öğrenenlerin, geri bildirim almayanlara göre önemli ölçüde daha yüksek puan aldıklarını vurgulamıştır. Bu çalışmaların bulgularından farklı olarak, Khan ve Pardo (2016) öğrenenlerin PDP görüntüleme sayısı ile ara sınav puanları arasında anlamlı bir ilişki bulunmadığını; Brouwer vd. (2016) ise PDP sunulan öğrenen grubunda önemli ölçüde daha yüksek bir performans gözlemlediklerini, ancak PDP kullanım sıklığı ile performans arasında istatistiksel olarak anlamlı bir ilişki olmadığını belirtmişlerdir.

Bu çalışmada, araştırma sorularında yer alan tüm değişkenler açısından deney ve kontrol grupları arasında istatistiksel olarak anlamlı bir fark olmakla birlikte bu farkın çok büyük olmadığı belirlenmiştir. Bu durum, öğrenenlerin böyle bir uygulamayı ilk defa kullanıyor olmalarından kaynaklanıyor olabilir. Bunun yanı sıra, PDP’de yer alan ilerleme durumu ve mesajlar teknik alt yapıdan dolayı öğrenen eylemlerine paralel ve gerçek zamanlı olarak gönderilememiştir. Oysa geri bildirimlerin gerçek zamanlı olarak gönderilmesi öğrenenleri eyleme geçirmek açısından oldukça önemlidir. Deney ve kontrol gruplarının ilgili değişkenler açısından ortalamalarındaki farkın düşük olmasının nedenlerinden biri, bu durum da olabilir. Bu bağlamda, ÖYS altyapısının gerçek zamanlı uygulamalara olanak sağlayacak şekilde ilişki veritabanı yapısından büyük veri analitiğine uygun bir yapıya dönüştürülmesi önerilebilir.

5.1.5. Öğrenme analitikleri tabanlı performans değerlendirme paneli ile ilgili öğrenen görüşleri

Bu aşamada, “Araştırma Sorusu 5: PDP kullanımına yönelik öğrenenlerin görüşleri ve memnuniyet düzeyleri nasıldır?” sorusuna yanıt aranmıştır. 2020-2021 öğretim yılı Bahar dönemi boyunca BIL102U dersinde deney grubundaki öğrenenlere PDP uygulaması sunulmuştur. Dönemin sonunda öğrenenlerin PDP’ye yönelik görüşlerinin ve memnuniyet düzeylerinin belirlenmesi amacıyla bir anket uygulanmıştır. Anket 2 tane 3’lü likert tipi, 25 tane 5’li likert tipi ve 1 tane açık uçlu maddeden oluşmaktadır. Bu maddeler öğrenenlerin PDP kullanımlarını, mesaj okuma durumlarını ve PDP’ye yönelik görüşlerini kapsamaktadır. Bu anketi, 451 öğrenen yanıtlamıştır.

Ankete katılan öğrenenlerin %92'si panelde kendilerine ait bilgileri her zaman ya da bazen incelediğini %8'i ise hiçbir zaman incelemediğini belirtmiştir. Bunun yanı sıra, her zaman incelediğini belirten kadınların oranı erkeklerden yüksekken, bazen incelediğini belirten erkeklerin oranı daha yüksektir. Ayrıca 42 yaş ve üstündeki öğrenenlerin PDP'yi inceleme durumlarının diğer yaş gruplarına göre daha yüksek olduğu belirlenmiştir. Öğrenenlerin PDP'yi inceleme sıklıkları harf notları bağlamında değerlendirildiğinde, diğerlerinden farklı olarak AA ve DC harf notlarındaki öğrenenlerin %50'ye yakını verileri her zaman incelediklerini belirtmişlerdir.

Ankete katılan öğrenenlerin %98'i gönderilen mesajları her zaman ya da bazen, %2'si ise hiçbir zaman okumadıklarını belirtmişlerdir. Yaş grupları açısından incelendiğinde 42 ve üstü yaş grubundaki öğrenenlerin mesajları her zaman okuma oranının diğer gruplardan daha yüksek olduğu görülmektedir. Öğrenenlerin harf notları bağlamında mesaj okuma sıklıkları incelendiğinde “her zaman” yanıtını veren öğrenen oranının en yüksek AA, BA ve DC harf notlarında yer aldığı görülmektedir. “Hiçbir zaman” yanıtının ise en yüksek DC, DD ve FF harf notlarındaki öğrenenler tarafından verildiği belirlenmiştir. Bu iki maddeye verilen yanıtlar incelendiğinde öğrenenlerin çoğunlukla PDP'yi inceledikleri ve gönderilen mesajları okudukları ifade edilebilir. Burada harf notları bağlamındaki farklılaşma dikkat çekici bir sonuç olarak değerlendirilebilir. Bu durum, akademik performans düzeyleri düşük olan öğrenenlerin malzeme kullanımlarının yanı sıra sistemle etkileşime girme düzeylerinin de düşük olduğu şeklinde yorumlanabilir. Bu durumun çözümüne yönelik olarak PDP ve geri bildirim mesajlarının yanı sıra öğrenenlere öğrenme süreçleri boyunca rehberlik edecek ve çalışma planları oluşturmalarını destekleyecek yapay zeka tabanlı uygulamalar geliştirilmesi önerilebilir.

Ankette PDP'ye yönelik algılanan fayda boyutunda 6, PDP'nin kullanılabilirliği boyutunda 8, mesajlara yönelik algılanan fayda boyutunda 6, mesajların kullanılabilirliği boyutunda 2 ve PDP'ye yönelik memnuniyet boyutunda ise 3 madde bulunmaktadır. Bu boyutlardaki tüm maddelere sırasıyla öğrenenlerin %60, %70, %70, %80 ve %77'den fazlası “Katılıyorum” ve “Kesinlikle katılıyorum” yanıtını vermişlerdir. Bu bulgular değerlendirildiğinde, PDP kullanımına yönelik görüşlerin yüksek oranda olumlu olduğu görülmektedir. Olumlu görüş oranının en yüksek olduğu boyutlar ise mesajların kullanılabilirliği ve PDP'ye yönelik memnuniyet olarak belirlenmiştir. Bañeres vd. (2020) tarafından yapılan

çalışmada da öğrenenlerin ilerleme durumlarına yönelik olarak gönderilen geri bildirim mesajlarının öğrenenler tarafından beğenildiği belirtilmiştir.

Öğrenenlerin PDP'ye yönelik görüşlerini açık uçlu olarak belirtmelerini istedikleri maddeye verdikleri yanıtlar incelendiğinde ise ders sorumlusundan mesaj almanın motive edici olduğu ve kendilerini önemli hissettirdiği, uygulamayı başarılı buldukları ve beğendikleri, uygulamanın yaygınlaştırılmasını istedikleri, panelin çalışma süreçlerine destek olduğu şeklinde yanıtların verildiği belirlenmiştir. Aguilar vd. (2021) de PDP kullanımı ile öğrenenlerin 7 hafta gibi kısa bir sürede dahi motivasyonlarında ve öz-düzenlemeli öğrenme süreçlerinde değişiklik olabileceğini vurgulamışlardır. Bunun yanı sıra, panelde geliştirme ve düzenlemelerin yapılması ve böyle bir uygulamaya ihtiyaç duymadıklarını belirten öğrenen yanıtları da bulunmaktadır. Bu nedenle, bu araçların kullanımının öğrenenin tercihinine bırakılması ve kişiselleştirme unsurlarının eklenmesinin önemli olduğu belirtilebilir.

PDP uygulama sürecinde elde edilen bulgular ve ankete verilen yanıtlar değerlendirildiğinde başarısız olma olasılığı yüksek olan öğrenenlerin sistem ve malzeme kullanımlarının yanı sıra kendilerine yönelik tasarlanan uygulamaları kullanma oranlarının da düşük olduğu görülmektedir. Bu öğrenenlerin sistemde devamlılıklarını sağlamak için farklı uygulamaların geliştirilmesi önerilebilir. Bu çalışma kapsamında, bir önceki dönem bir derste başarısız olan öğrenenlere aynı dersin devam dersinde PDP ve geri bildirim uygulamanın sunulması ve süreçlerinin yakından takip edilmesi planlanmış ancak COVID-19 pandemisi nedeniyle ardışık dönemler yerine farklı dönemlerdeki veriler ile çalışılması gerekmiştir. Bu çalışmada geliştirilen akademik performans tahmin modeli kullanılarak başarısız olma olasılığı olan öğrenenlere farklı motivasyonel stratejiler uygulanması, derse devamın artmasına ve akademik performansın yükseltilmesine olanak sağlayabilir.

5.2. Öneriler

Bu çalışmada kitlesel açık ve uzaktan öğrenme sisteminde öğrenme yönetim sistemini kullanan öğrenenlerin öğrenme malzemeleri kullanım örüntüleri ve öğrenen profilleri belirlenmiş, akademik performanslarına yönelik tahmin modeli geliştirilmiş, öğrenme yönetim sistemine entegre olarak çalışabilen bir PDP tasarlanmıştır ve PDP'nin öğrenme sürecindeki etkileri incelenmiştir. Bu çalışmadan elde edilen bulgular ve sonuçlar bağlamında kitlesel açık ve uzaktan öğrenme sistemlerinde; ÖYS'lerde büyük veri analitiğine uygun altyapıların kullanılmasının, gerçek zamanlı veri analizi ile otomatik raporlama sistemlerinin tasarlanmasının, sonuç odaklı ölçme ve değerlendirme yerine süreç odaklı ölçme ve değerlendirme yaklaşımının benimsenmesinin ve öğrenme sürecinde yapay zeka tabanlı uygulamalar ile öğrenenlere destek olunmasının önemli olduğu belirtilebilir.

Bu çalışmada, öğrenenlerin çalışma örüntülerinin sonuçlarında çıkmış sınav soruları ve ünite özetinin yer aldığı belirlenmiştir. Öğrenenlerin benzer çalışma örüntüleri sergilediği, ancak bu durumun genel not ortalaması ve sistem kullanım metrikleri açısından farklılaştığı görülmüştür. Bu sonuç, öğrenenlerin malzeme kullanımlarına yönelik bilgi sağlamanın ötesinde öğrenenlere stratejiler ve öneriler sunulmasına katkı sağlayabilir. Bu da öğrenenlerin öğrenme süreçlerinin desteklenmesine ve akademik performanslarının yükselmesine olanak sunabilir. Bunun yanı sıra, öğrenenlerin sınav döneminde özellikle deneme sınavı kullanımlarındaki artış göz önüne alındığında deneme sınavlarının öğrenenlerin öğrenmelerine destek olacak konu ile ilgili kısa bilgilerin yer aldığı etkileşimli bir yapıya dönüştürülmesi önerilebilir.

Bu çalışmadan elde edilen sonuçlar bağlamında, öğrenenlerin öğrenme malzemeleri kullanım örüntülerinin daha detaylı olarak incelemesi için öğrenme malzemelerine çalışırken öğrenen hareketlerinin izlenebildiği malzeme türleri, veri depolama ve veri analizi altyapıları kurulması önerilmektedir.

Bu çalışmanın sonuçları değerlendirildiğinde, öğrenenlerin daha çok sınav dönemlerinde çalıştıkları ve çıkmış sınav sorularını kullandıkları görülmektedir. Bu durumun değiştirilebilmesi için sürekli değerlendirmeye geçilmesi; projeler, ödevler ve görevlerin sürece dahil edilmesi ve etkinlik tabanlı tasarımların kullanılması önerilmektedir.

Öğrenenlerin sınav dönemi öncesinde de malzeme erişimlerinin yükseltilmesi için motivasyonlarını artırabilecek ve çalışma stratejisi geliştirmelerine yardımcı olabilecek uygulamalar geliştirilebilir. Bu amaçla, bu çalışma kapsamında geliştirilen PDP gibi geri bildirim bileşeni de içeren araçlar kullanılabilir.

Çalışma kapsamında elde edilen öğrenen profilleri değerlendirildiğinde, akademik başarı notu ve öğrenme malzemeleri erişimi değişkenleri profillerin tanımlanmasında ön plana çıkmıştır. Bu çalışmada öğrenenlerin demografik özellikleri, küme kalitesini olumsuz etkilediği için analizlere dahil edilmemiş ancak kümelerin tanımlanmasında kullanılmıştır. Bu bağlamda, profillerin yorumlanması ve öğrenenlerin daha iyi anlaşılabilmesi için öğrenenlerin kayıt amaçlarına, motivasyon ve hedeflerine yönelik araştırmaların yapılmasının önemli olduğu vurgulanabilir. Eğitim kurumlarındaki öğrenen özellikleri birbirinden farklı olabileceğinden bu çalışmaları, kurumların kendi bünyelerinde gerçekleştirmeleri önerilebilir.

Bu çalışmada elde edilen öğrenen profillerinde yaş ortalaması yükseldikçe akademik başarı notunun yükseldiği söylenebilir. Yüksek Erişim ve Yüksek Puan grubundaki öğrenenlerin yaş ortalamaları diğer gruplara göre daha yüksektir. Düşük Puan ve Ortalama Altı Puan grubundaki öğrenenlerin ise daha küçük yaş ortalamasına sahip olduğu belirlenmiştir. Öğrenenlerin davranış örüntüleri ve öğrenen profilleri birlikte değerlendirildiğinde, 42 yaş ve üstündeki öğrenenlerin malzeme kullanım örüntüleri, sistem erişimleri ve buldukları profil grupları açısından diğer yaş gruplarından farklılaştıkları görülmektedir. Bu bağlamda, orta yaş ve üstündeki öğrenenlerin ihtiyaçları ve ilgileri araştırılarak bu öğrenenlere özgü yeni programlar tasarlanabilir. Çalışmada, Düşük Puan grubundaki öğrenenlerin sınava girme oranlarının oldukça düşük olduğu görülmüştür. Çalışmadaki öğrenenlerin %17'sinin bu grupta yer aldığı göz önüne alındığında, büyük sayıdaki bir öğrenen grubunun sınava bile girmeden sistemden ayrılacağı ya da başarısız olabileceği değerlendirilebilir. Bu öğrenen profilindeki öğrenenler, süreç boyunca daha fazla desteğe ihtiyaç duyabileceklerinden dolayı kendileriyle iletişim kurulması, sistemde kalmalarını sağlayabilir. Bu gruptaki öğrenenlerin özellikleri ile akademik performans tahmin modeli sonuçları birleştirilerek risk durumundaki bu öğrenenlere yönelik erken müdahale sistemlerinin geliştirilmesine yönelik çalışmalar artırılabilir.

Çalışma kapsamında öğrenenlerin harf notlarının tahmin edilmesine yönelik farklı öznelik setleri ve algoritmalar kullanılmıştır. Özneliklerin tahmin gücünün algoritmalara göre farklılık gösterdiği belirlenmiştir. Tahmin gücü en yüksek olan öznelikler, ara sınav puanı ve sınava girme oranı olmuştur. Sadece bu iki öznelik kullanılarak bu çalışmada elde edilen en yüksek tahmin doğruluğuna yakın modeller geliştirilebildiği belirlenmiştir. Bu sonuç değerlendirildiğinde, öğrenenlerin akademik performanslarının ara sınav sonrasında tahmin edilebileceği görülmektedir. Bunun yanı sıra, algoritmaların başarısız olma olasılığı olan öğrenenleri yüksek doğrulukla tahmin edebildiği anlaşılmıştır. PDP gibi erken uyarı sunulmasına olanak sağlayan araçlar kullanılarak risk durumundaki öğrenenler uyarılabilir ve eyleme geçmelerine yönelik stratejiler sunulabilir. Bu sayede, hem öğrenenlerin sistemden ayrılmalarının ve başarısız olmalarının önüne geçilebilir hem de kurum kaynakları daha etkili bir şekilde kullanılabilir.

Bu çalışmada öğrenenlere, ilerleme durumlarını gösteren PDP ve geri bildirim mesajları sunulmuştur. Öğrenenlerin PDP'ye yönelik görüşleri çoğunlukla olumlu olmakla birlikte böyle bir uygulamaya ihtiyaç duymadığını belirten öğrenenler de bulunmaktadır. Bu nedenle, bu araçların kullanımının öğrenenin tercihine bırakılması önerilmektedir. Bunun yanı sıra, öğrenenlerin bir bölümü diğer öğrenenlerin de çalışmalarını görmek isterken diğerleri ise bunu istemediklerini belirtmişlerdir. Bu bağlamda, PDP'ye kişiselleştirme unsurlarının eklenmesinin ve öğrenenlerin kendi ihtiyaçlarına göre PDP bileşenlerini ekleyip çıkarmalarına olanak sağlanmasının önemli olduğu değerlendirilebilir. PDP araçları, öğrenenlerin öz-düzenlemeli öğrenme becerilerini ve öğrenme sürecine ilişkin üstbilişlerini destekleyebilir. Gelecek araştırmalarda, öğrenme analitikleri kullanılarak PDP'nin öz-düzenlemeli öğrenme becerileri ve üstbiliş üzerindeki etkilerinin incelenmesi önerilebilir.

Bu çalışmanın önemli sonuçlarından biri, açık ve uzaktan öğrenmede öğrenenlerin ders sorumlusunu tanımalarının ve iletişim kurmalarının aidiyetleri ve motivasyonları üzerindeki olumlu etkisidir. Buna ek olarak, öğrenenlere ders sorumlusu tarafından çalışma süreçlerine ilişkin geri bildirimler verildiğinde öğrenenlerin kullandıkları öğrenme malzemelerinde de değişim yaşandığı belirlenmiştir. Öğrenenlerin genel malzeme kullanım tercihi çıkmış sınav soruları olmakla birlikte geri bildirim mesajlarının ardından ders kitabını kullanmayı tercih ettikleri gözlemlenmiştir. Bu durum, öğrenenlerin çalışma alışkanlıkları analiz edilerek gönderilen mesajların öğrenenlerin çalışma alışkanlıklarını değiştirebileceği şeklinde

yorumlanabilir. Birliktelik kuralları, sıralı örüntü madenciliği ve kural çıkarımı gibi yöntemler ile elde edilen sonuçlar kullanılarak öğrenenlerin çalışma süreçlerine destek sağlanabilir. Buradan elde edilen gruplara otomatik mesajlar gönderilebilir ve öneriler sunulabilir. Çalışma kapsamında öğretenden öğrenene tek yönlü bir iletişim gerçekleştirilmiş, öğrenenler öğretene mesaj gönderememiştir. Çift yönlü bir iletişim ortamı sağlanarak öğrenenlerin de görüşleri değerlendirilebilir, katılımları yükseltilebilir ve daha demokratik bir ortam oluşturulabilir. Ancak, öğrenen sayısının çok olduğu açık ve uzaktan öğrenme ortamlarında bu yanıtların takip edilmesi ve yanıtlanması için uygun altyapıların geliştirilmesi oldukça önemlidir. Yanıtsız bırakılan mesajlar, öğrenenlerin sistemden uzaklaşmasına ve mesajların inandırıcılığının azalmasına neden olabilir. Mesajların yanıtlanması ve takip edilmesi için yapay zeka tabanlı uygulamaların geliştirilmesine yönelik çalışmalara ağırlık verilebilir.

Bu çalışmada, PDP'nin öğrenme sürecindeki etkilerinin incelenmesi için öğrenenler seçkisiz olarak deney ve kontrol gruplarına atanmışlardır. Yapılan testler sonucunda deney grubundaki öğrenenlerin akademik performans, oturum açtıkları gün sayısı, oturum açma sayıları ve öğrenme malzemelerine erişim sayıları açısından kontrol grubundaki öğrenenlerden daha yüksek ortalamalara sahip oldukları belirlenmiştir. Bu sonuç değerlendirildiğinde, PDP'lerin açık ve uzaktan eğitim veren diğer kurumlarda da kullanılmasının olumlu sonuçlar yaratabileceği öngörülmektedir. Bu çalışma kapsamında, PDP'nin geliştirilme süreçleri, bileşenleri ve kullanılan teknolojiler açıklanmıştır. PDP tasarımında öğrenenler için değerli bilgilerin belirlenmesinin, karmaşıklığın azaltılması için öğrenme malzeme türlerinin gruplanarak sunulmasının ve PDP'nin kolaylıkla anlaşılabilir olmasının önemli olduğu belirtilebilir. Bu çalışmada PDP geliştirilmesine yönelik sunulan yol haritasının, açık ve uzaktan eğitim veren diğer kurumların kendi öğrenen ve kurum ihtiyaçlarını göz önüne alarak PDP geliştirmelerine destek olabileceği düşünülmektedir.

Kitlesele açık ve uzaktan öğrenme sistemlerinde öğrenenlerin yalnız hissetmelerinin önüne geçilmesi, motivasyonlarının yükseltilmesi, öğrenenlere rehberlik edilmesi ve çalışma strateji önerilerinin sunulabilmesi için yapay zeka tabanlı sanal öğretim asistanları geliştirilebilir. Bu çalışmadan elde edilen modeller, bu asistanın karar ve rehberlik süreçlerinin eğitilmesinde kullanılabilir.

Bu çalışma kapsamında geliştirilen tanımlayıcı, tahmin edici ve normatif analitiklerin birbirine bağlı süreçler ve otomatikleşmiş olarak çalışabilmeleri için ÖYS altyapısının büyük veri depolama ve analizine uygun bir yapıya dönüştürülmesinin önemli olduğu düşünülmektedir. Bu sayede, modeller gerçek zamanlı olarak akan öğrenen verilerine dayalı olarak dinamik bir yapıda güncellenebilir ve daha doğru kararlar verilebilir. Bu çalışmada, bu sınırlılıktan dolayı geri bildirim mesajları anlık olarak gönderilememiştir. Büyük veri altyapısına geçilmesiyle bu mesajlar, öğrenenlerin hareketleri analiz edilerek gerçek zamanlı ve otomatik olarak verilebilir.

Bu çalışma, öğrenme analitiklerine dayalı olarak büyük veriler üzerinde analizler yapılarak gerçekleştirilmiştir. Açık ve uzaktan öğrenme sistemlerinde öğrenenlere ait pek çok veri elde edilmekle birlikte analizlerden önce veri türleri ve doğasının incelenmesi ve anlaşılması için çalışmaların yapılması oldukça önemlidir. Bu bağlamda araştırmacılara çalışma yapacakları verileri iyi tanımları ve amaçlarını net bir şekilde belirlemeleri önerilmektedir. Bunun yanı sıra, kullanılan yöntemlerin doğruluğunu belirleyen yöntemler bulunmaktadır. Ancak en yüksek değer, her zaman amaca en çok hizmet eden değer olmayabilir. Bu nedenle çıktılar, eğitsel önem açısından da değerlendirilmeli ve amaca en uygun çözüm üzerinden çalışmalar sürdürülmelidir. Büyük sayıda ve boyuttaki verilerle çalışmanın en büyük zorluklarından biri, süreç takibidir. Bu nedenle veri sözlüğü oluşturulması, yapılan işlemlerin ve analizlerin aynı zaman diliminde raporlanması çalışma sürecinin daha tutarlı ilerlemesini sağlayabilir.

KAYNAKÇA

- Agrawal, R. and Srikant, R. (1994). Fast algorithms for mining association rules. In *Proceedings 20th International Conference on Very Large Databases*, 1215, pp. 487-499.
- Agrawal, R., Imieliński, T. and Swami, A. (1993). Mining association rules between sets of items in large databases. In *Proceedings of The 1993 ACM SIGMOD International Conference on Management of Data*, pp. 207-216.
- Aguilar, S. J., Karabenick, S. A., Teasley, S. D., Baek, C. (2021). Associations between learning analytics dashboard exposure and motivation and self-regulated learning. *Computers & Education*, 162, 1-11.
- Akçapınar, G. ve Uz Bilgin, Ç. (2020). Öğrenme analitiklerine dayalı oyunlaştırılmış gösterge paneli kullanımının öğrencilerin çevrimiçi öğrenme ortamındaki bağlılıklarına etkisi. *Kastamonu Eğitim Dergisi*, 28(4), 1892-1901. DOI: 10.24106/kefdergi.740489
- Ali, L., Hatala, M., Gašević, D., Jovanović, J. (2012). A qualitative evaluation of evolution of a learning analytics tool. *Computers & Education*, 58(1), 470-489.
- Aljohani, N. R., Daud, A., Abbasi, R. A., Alowibdi, J. S., Basher, M., Aslam, M. A. (2019). An integrated framework for course adapted student learning analytics dashboard. *Computers in Human Behavior*, 92, 679-690.
- Amershi, S. and Conati, C. (2009). Combining unsupervised and supervised machine learning to build user models for exploratory learning environments. *Journal of Educational Data Mining*, 1(1), 18-71.
- Anadolu Üniversitesi. (2021). Anadolium eKampus. <https://ekampus.anadolu.edu.tr/> (Erişim tarihi: 15.09.2021)
- Anderson, T. (Ed.). (2008). *The theory and practice of online learning*. Athabasca University Press.
- Arnold, K. E. and Pistilli, M. D. (2012). Course Signals at Purdue: Using learning analytics to increase student success. *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, ACM, pp. 267-270.
- AÜ. (2021a). <https://www.anadolu.edu.tr/acikogretim/yurtdisi-programlari> (Erişim tarihi: 12.09.2021).

- AÜ. (2021b). <https://www.anadolu.edu.tr/acikogretim/turkiye-programlari> (Erişim tarihi: 12.09.2021).
- AÜ. (2021c). <https://www.anadolu.edu.tr/acikogretim/yurtdisi-programlari> (Erişim tarihi: 12.09.2021).
- AÜ. (2021d). <http://ikinciuniversite.anadolu.edu.tr/index.html> (Erişim tarihi: 12.09.2021).
- Aybek, H. S. Y. and Okur, M. R. (2016). Predicting achievement with neural networks: The case of Anadolu University. *Global Learn* içinde (s.561-568), Association for the Advancement of Computing in Education (AACE).
- Azcona, D., Hsiao, I. H. and Smeaton, A. F. (2019). Detecting students-at-risk in computer programming classes with learning analytics from students' digital footprints. *User Modeling and User-Adapted Interaction*, 29(4), 759-788.
- Baker, R. S. (2015). *Big data and education* (2nd ed.). New York, NY: Teachers College, Columbia University.
- Bañeres, D., Rodríguez, M. E., Guerrero-Roldán, A. E., Karadeniz, A. (2020). An early warning system to detect at-risk students in online higher education. *Applied Sciences*, 10(13), 4427.
- Barto, A. G. and Dietterich, T. G. (2004). Reinforcement learning and its relationship to supervised learning. J. Si, A. Barto, W. Powell, D. Wunsch (Editörler), *Handbook of learning and approximate dynamic programming* içinde (s. 47-63). London: IEEE Press, Wiley.
- Bates, A. W. (2015). *Teaching in a digital age: Guidelines for teaching and learning*. <https://opentextbc.ca/teachinginadigitalage/> (Erişim Tarihi: 05.01.2018).
- Bawa, P. (2016). Retention in online courses: Exploring issues and solutions-A literature review. *Sage Open*, 6(1), 1-11.
- Bodily, R. and Verbert, K. (2017). Review of research on student-facing learning analytics dashboards and educational recommender systems. *IEEE Transactions on Learning Technologies*, 10(4), 405-418.
- Bodily, R., Ikahihifo, T. K., Mackley, B., Graham, C. R. (2018). The design, development, and implementation of student-facing learning analytics dashboards. *Journal of Computing in Higher Education*, 30(3), 572-598.

- Bouchet, F., Harley, J. M., Trevors, G. J., Azevedo, R. (2013). Clustering and profiling students according to their interactions with an intelligent tutoring system fostering self-regulated learning. *JEDM-Journal of Educational Data Mining*, 5(1), 104-146.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Breunig, M. M., Kriegel, H. P., Ng, R. T., Sander, J. (2000). LOF: Identifying density-based local outliers. In *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, Dallas, Texas, USA: ACM Press, pp. 93–104.
- Brouwer, N., Bredeweg, B., Latour, S., Berg, A., van der Huizen, G. (2016). Learning analytics pilot with coach2-Searching for effective mirroring. *European Conference on Technology Enhanced Learning Springer*, Cha, pp. 363-369.
- Campbell, J. P. and Oblinger, D. G. (2007). Academic analytics. *Educause Quarterly*, 24.
- Cerezo, R., Sánchez-Santillán, M., Paule-Ruiz, M. P., Núñez, J. C. (2016). Students' LMS interaction patterns and their relationship with achievement: A case study in higher education. *Computers & Education*, 96, 42-54.
- Charleer, S., Klerkx, J., Duval, E., Verbert, K., De Laet, T. (2016). Creating effective learning analytics dashboards: lessons learnt. *LNCS*, 9891, 42–56. doi:10.1007/978-3-319-45153-44.
- Chassignol, M., Khoroshavin, A., Klimova, A., Bilyatdinova, A. (2018). Artificial intelligence trends in education: A narrative overview. *Procedia Computer Science*, 136, 16-24.
- Chen, L., Chen, P. and Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278. doi:10.1109/access.2020.298851
- Chen, L., Lu, M., Goda, Y., Yamada, M. (2019). Design of learning analytics dashboard supporting metacognition. *CELDA*, 175-182.
- Christoforou, A. P. and Yigit, A. S. (2008). Improving teaching and learning in engineering education through a continuous assessment process. *European Journal of Engineering Education*, 33(1), 105-116.
- Ciolacu, M., Tehrani, A. F., Beer, R., Popp, H. (2017). Education 4.0—Fostering student's performance with machine learning methods. In *2017 IEEE 23rd International Symposium for Design and Technology in Electronic Packaging*, IEEE, pp. 438-443.

- Click, C., Lanford, J., Malohlava, M., Parmar, V., Roark, H. (2015). *Gradient boosted machines with H2O*. H2O.ai, Inc.
- Clow, D. (2013). An overview of learning analytics. *Teaching in Higher Education*, 18(6), 683-695.
- Conde, M. A., García-Peñalvo, F. J., Gómez-Aguilar, D. A., Therón, R. (2015). Exploring software engineering subjects by using visual learning analytics techniques. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 10(4), 242-252.
- Copeland, M. (2016). What's the difference between artificial intelligence, machine learning and deep learning?. <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/> (Erişim tarihi: 12.09.2021).
- Corrin, L. and De Barba, P. (2015). How do students interpret feedback delivered via dashboards?. *Proceedings of the fifth international conference on learning analytics and knowledge*, pp. 430-431.
- Creswell, J. W. (2012). *Educational research: Planning, conducting, and evaluating quantitative and qualitative research* (4th ed.). Boston, MA: Pearson Education.
- Cruz-Benito, J., Therón, R., García-Peñalvo, F. J., Lucas, E. P. (2015). Discovering usage behaviors and engagement in an Educational Virtual World. *Computers in Human Behavior*, 47, 18-25.
- Daniel, J. (1996). *Mega-universities and knowledge media: Technology strategies for higher*
- Davies, D. L. and Bouldin, D. W. (1979). A cluster separation measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-1(2), 224–227. doi:10.1109/TPAMI.1979.4766909.
- Dawson, S., Bakharia, A. and Heathcote, E. (2010). SNAPP: Realising the affordances of real-time SNA within networked learning environments. *Proceedings of the 7th International Conference on Networked Learning 2010*, 125-133.
- Dolla'r, A. and Steif, P. S. (2012). Web-based statics course with learning dashboard for instructors. *Proceedings of computers and advanced technology in education (CATE 2012)*, June 25–27, 2012, Napoli, Italy.
- Du, X., Yang, J., Shelton, B. E., Hung, J. L., Zhang, M. (2021). A systematic meta-Review and analysis of learning analytics research. *Behaviour & Information Technology*, 40(1), 49-62.

- Duda, R. O. and Hart, P. E. (1973). *Pattern classification and scene analysis*. New York: John Wiley & Sons.
- Dunham, M. H. (2003). *Data mining: Introductory and advanced topics*. New Jersey: Pearson Education.
- Duval, E. (2011). Attention please! Learning analytics for visualization and recommendation. *Proceedings of the 1st International Conference on Learning Analytics and Knowledge*, pp. 9-17.
- Duval, E. and Verbert, K. (2012). Learning analytics. *ELEED: E-Learning and Education*, 8(1).
- Dwivedi, P. and Bharadwaj, K. K. (2015). e-Learning recommender system for a group of learners based on the unified learner profile approach. *Expert Systems*, 32(2), 264-276. *education*. London: Kogan Page.
- Eynon, R. (2015). The quantified self for learning: critical questions for education. *Learning, Media and Technology*, 40(4), 407-411. DOI: 10.1080/17439884.2015.1100797
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 1189-1232.
- Friedman, J., Hastie, T. and Tibshirani, R. (2008). *The elements of statistical learning: Data mining, inference and prediction* (2nd ed.). New York: Springer Series in Statistics.
- Friedman, N., Geiger, D. and Goldszmidt, M. (1997). Bayesian network classifiers. *Machine Learning*, 29(2), 131-163.
- Gartner (2021). <https://www.gartner.com/en/information-technology/glossary/prescriptive-analytics> (Erişim tarihi: 12.09.2021).
- Gašević, D., Dawson, S. and Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64-71.
- Gašević, D., Dawson, S., Rogers, T., Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68-84.
- Gay, L. R., Mills, G. E. and Airasian, P. (2012). *Educational research: Competencies for analysis and applications* (10th ed.). London: Pearson Education.

- Goldstein, M. and Uchida, S. (2016). A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data. *PLoS ONE*, 11(4). <https://doi.org/10.1371/journal.pone.0152173>.
- Goode, C., Terry, A., Harlow, H., Cash, R. (2021). Mining for gold: Learning analytics and design for learning: A review. *Scope: (Teaching & Learning)*, 10, 74-82.
- Govaerts, S., Verbert, K., Duval, E., Pardo, A. (2012). The student activity meter for awareness and self-reflection. *CHI'12 Extended Abstracts on Human Factors in Computing Systems*, pp. 869-884.
- Graf, S. and Kinshuk. (2013). Dynamic student modelling of learning styles for advanced adaptivity in learning management systems. *International Journal of Information Systems and Social Change (IJISSC)*, 4(1), 85-100.
- Graf, S., Liu, T. C. and Kinshuk (2010). Analysis of learners' navigational behaviour and their learning styles in an online course. *Journal of Computer Assisted Learning*, 26(2), 116-131.
- Gürsoy, U. T. (2012). *Uygulamalı veri madenciliği: Sektörel analizler*. Ankara: Pegem Akademi Yayıncılık.
- H2O. (2021). <http://h2o-release.s3.amazonaws.com/h2o/master/1752/docs-website/datascience/deeplearning.html> (Erişim tarihi: 12.09.2021).
- Hagerty, J. (2017). *2017 planning guide for data and analytics*. Gartner Inc, 13.
- Hajkowicz, S., Karimi, S., Wark, T., Chen, C., Evans, M., Rens, N., ... & Tong, K. J. (2019). Artificial Intelligence: Solving problems, growing the economy and improving our quality of life. <https://apo.org.au/node/268341>
- Han, J., Kamber, M. and Pei, J. (2012). *Data mining: Concepts and techniques* (3rd ed.). San Francisco, CA: Morgan Kaufmann.
- Hernández, R. (2012). Does continuous assessment in higher education support student learning?. *Higher Education*, 64(4), 489-502.
- Hofmann, M. and Klinkenberg, R. (2016). *RapidMiner: Data mining use cases and business analytics applications*. CRC Press.
- Hogo, M. A. (2010). Evaluation of e-learners behaviour using different fuzzy clustering models: a comparative study. *International Journal of Computer Science and Information Security*, 7(2), 131-140.

- Holmes, N. (2018). Engaging with assessment: Increasing student engagement through continuous assessment. *Active Learning in Higher Education*, 19(1), 23-34.
- Hu, Y. H., Lo, C. L. and Shih, S. P. (2014). Developing early warning systems to predict students' online learning performance. *Computers in Human Behavior*, 36, 469-478.
- Hung, J. L. and Crooks, S. M. (2009). Examining Online Learning Patterns with Data Mining Techniques in Peer-Moderated and Teacher-Moderated Courses. *Journal of Educational Computing Research*, 40(2), 183–210. doi:10.2190/ec.40.2.c
- Hung, J. L. and Zhang, K. (2008). Revealing online learning behaviors and activity patterns and making predictions with data mining techniques in online teaching. *MERLOT Journal of Online Learning and Teaching*, 4(4), 426-437.
- IBM. (2011). IBM SPSS Modeler 14.2 modeling nodes. <ftp://ftp.software.ibm.com/software/analytics/spss/documentation/modeler/14.2/en/ModelingNodes.pdf> (Erişim tarihi: 05.01.2018).
- IBM. (2014). https://www.ibm.com/docs/en/db2/11.1?topic=SSEPGG_11.1.0/com.ibm.im.model.doc/c_lift_in_an_association_rule.html (Erişim tarihi: 12.09.2021).
- IBM. (2017). Descriptive, predictive, prescriptive: transforming asset and facilities management with analytics. <https://www-01.ibm.com/common/ssi/cgi-bin/ssialias?infotype=SA%26subtype=WH%26htmlfid=TIW14162USEN> (Erişim tarihi: 05.01.2018).
- IBM. (2021a). Data mining. <https://www.ibm.com/cloud/learn/data-mining> (Erişim tarihi: 12.09.2021).
- IBM. (2021b). <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks> (Erişim tarihi: 12.09.2021).
- IBM. (2021c). Machine learning. <https://www.ibm.com/cloud/learn/machine-learning> (Erişim tarihi: 12.09.2021).
- Ifenthaler, D. and Yau, J. Y. K. (2020). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development*, 68(4), 1961-1990.
- Jivet, I. (2021). *The dashboard that loved me: Designing adaptive learning analytics for self-regulated learning*. Yayınlanmamış Doktora Tezi. Limburg: Open Universiteit.

- Jivet, I., Scheffel, M., Drachler, H., Specht, M. (2017). Awareness is not enough: Pitfalls of learning analytics dashboards in the educational practice. *European Conference on Technology Enhanced Learning*, pp. 82-96. Springer, Cham.
- Jivet, I., Scheffel, M., Schmitz, M., Robbers, S., Specht, M., Drachler, H. (2020). From students with love: An empirical study on learner goals, self-regulated learning and sense-making of learning analytics in higher education. *The Internet and Higher Education*, 47, 1-14.
- Joksimović, S., Kovanović, V. and Dawson, S. (2019). The journey of learning analytics. *HERDSA Review of Higher Education*, 6, 27-63.
- Jovanovic, M., Vukicevic, M., Milovanovic, M., Minovic, M. (2012). Using data mining on student behavior and cognitive style data for improving e-learning systems: A case study. *International Journal of Computational Intelligence Systems*, 5(3), 597-610.
- Jurafsky, D. and Martin, J. H. (2021). *Speech and language processing: An introduction to natural language processing*. <https://web.stanford.edu/~jurafsky/slp3/ed3book.pdf> (Erişim tarihi: 12.09.2021).
- Kang, M. and Jameson, N. J. (2018). Machine learning: Fundamentals. *Prognostics and Health Management of Electronics: Fundamentals, Machine Learning, and the Internet of Things*, 85-109.
- Karaoglan Yilmaz, F. G. and Yilmaz, R. (2021). Learning analytics as a metacognitive tool to influence learner transactional distance and motivation in online learning environments. *Innovations in Education and Teaching International*, 58(5), 575-585.
- Keller, J. M. (1987). Development and use of the ARCS model of motivational design. *Journal of Instructional Development*, 10(3), 2-10.
- Keller, J. M. (2010). *Motivational design for learning and performance: The ARCS model approach*. New York: Springer.
- Kemsley, B. (2020). Continuous improvement dashboards. R. Kimmons and S. Caskurlu (Editörler), *The Students' Guide to Learning Design and Research* içinde. EdTech Books. https://edtechbooks.org/studentguide/continuous_improvement (Erişim tarihi: 12.09.2021).

- Kerly, A., Ellis, R. and Bull, S. (2007). CALMsystem: a conversational agent for learner modelling. *International Conference on Innovative Techniques and Applications of Artificial Intelligence*, pp. 89-102. Springer, London.
- Khalil, M. and Ebner, M. (2015). Learning analytics: Principles and constraints. *Proceedings of World Conference on Educational Multimedia, Hypermedia and Telecommunications*, pp. 1326-1336.
- Khan, I. and Pardo, A. (2016). Data2U: Scalable real time student feedback in active learning environments. *Proceedings of The Sixth International Conference on Learning Analytics & Knowledge*, pp. 249-253.
- Kia, F. S., Teasley, S. D., Hatala, M., Karabenick, S. A., Kay, M. (2020). How patterns of students dashboard use are related to their achievement and self-regulatory engagement. *Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, pp. 340-349.
- Kim, J., Jo, I. H. and Park, Y. (2016). Effects of learning analytics dashboard: analyzing the relations among dashboard utilization, satisfaction, and learning achievement. *Asia Pacific Education Review*, 17(1), 13-24.
- Klerkx, J., Verbert, K. and Duval, E. (2017). Learning analytics dashboards. C. Lang, G. Siemens, A. Wise, D. Gasevic (Editörler), *Handbook of Learning Analytics* içinde (s.143-150), New York, NY, USA: SOLAR, Society for Learning Analytics and Research.
- Knight, D. B., Brozina, C., Stauffer, E. M., Frisina, C., Abel, T. D. (2015). Developing a learning analytics dashboard for undergraduate engineering using participatory design. *2015 ASEE Annual Conference & Exposition*, pp. 26-485.
- Kokoç, M. and Altun, A. (2019). Effects of learner interaction with learning dashboards on academic performance in an e-learning environment. *Behaviour & Information Technology*, 40(2), 1-15.
- Kotsiantis, S. B., Patriarcheas, K. and Xenos, M. (2010). A combinational incremental ensemble of classifiers as a technique for predicting students' performance in distance education. *Knowledge-Based Systems*, 23(6), 529– 535.
- Kotu, V. and Deshpande, B. (2014). *Predictive analytics and data mining: Concepts and practice with Rapidminer*. Morgan Kaufmann.

- Langley, P. and Sage, S. (1994). Induction of selective Bayesian classifiers. In R. L'opez de Mantar'as and D. Poole (Editörler), *Proceedings of the Tenth Conference on Uncertainty in Artificial Intelligence*, pp. 399-406. San Francisco, CA: Morgan Kaufmann.
- Langley, P. and Thompson, K. (1992). An analysis of Bayesian classifiers. *Proceedings of The Tenth National Conference on Artificial Intelligence*, pp. 223–228. Menlo Park, CA: AAAI Press.
- learning in the global classroom*. Alexandria, VA: ASCD.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee, Y. and Choi, J. (2011). A review of online course dropout research: Implications for practice and future research. *Educational Technology Research and Development*, 59(5), 593-618.
- Leitner P., Khalil M., Ebner M. (2017) Learning Analytics in Higher Education-A Literature Review. In: A. Peña-Ayala (Editör), *Learning Analytics: Fundaments, Applications, and Trends. Studies in Systems, Decision and Control*, 94. Springer, Cham. https://doi.org/10.1007/978-3-319-52977-6_1
- Leony, D., Pardo, A., de la Fuente Valentín, L., de Castro, D. S., Kloos, C. D. (2012). GLASS: a learning analytics visualization tool. *Proceedings of The 2nd International Conference on Learning Analytics and Knowledge*, 162-163.
- Li, I., Dey, A. and Forlizzi, J. (2010). A stage-based model of personal informatics systems. *Proceedings of CHI10: 28th International Conference on Human Factors in Computing Systems*, New York, NY: ACM, pp. 557-566.
- Love, J., DeMonner, S. and Teasley, S. (2021). Show students their data: Using dashboards to support self-regulated learning. *Educause Review*. <https://er.educause.edu/articles/2021/7/show-students-their-data-using-dashboards-to-support-self-regulated-learning> (Eriřim tarihi: 12.09.2021).
- Macfadyen, L. P. and Dawson, S. (2010). Mining LMS data to develop an “early warning system” for educators: A proof of concept. *Computers & Education*, 54(2), 588-599.
- Macfadyen, L. P. and Dawson, S. (2012). Numbers are not enough: Why e-learning analytics failed to inform an institutional strategic plan. *J. Educ. Technol. Soc.*, 15(3), 149-163.

- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. *The Fifth Berkeley Symposium on Mathematical Statistics and Probability*. Berkeley, CA, USA: University of California Press, pp. 281-297.
- Mangaroska, K. and Giannakos, M. (2019). Learning analytics for learning design: A systematic literature review of analytics-driven design to enhance learning. *IEEE Transactions on Learning Technologies*, 12(4), 516-534. doi: 10.1109/TLT.2018.2868673.
- Matcha, W., Gašević, D. and Pardo, A. (2019). A systematic review of empirical studies on learning analytics dashboards: A self-regulated learning perspective. *IEEE Transactions on Learning Technologies*, 13(2), 226-245.
- Microsoft. (2021). <https://docs.microsoft.com/en-us/azure/machine-learning/component-reference/multiclass-logistic-regression> (Erişim tarihi: 12.09.2021).
- Milne, J., Jeffrey, L. M., Suddaby, G., Higgins, A. (2012). Early identification of students at risk of failing. In *Australian Society for Computers in Learning in Tertiary Education Annual Conference (ASCILITE)*, 1, 25-28.
- Moore, M. G. and Kearsley, G. (2011). *Distance education: A systems view of online learning* (3rd. ed.). Wadsworth: Cengage Learning.
- Mouaici, M., Vignollet, L., Galez, C., Etienne, M. (2018). Learning analytics dashboards for professional training-challenges and proposal. *Thirteenth European Conference on Technology Enhanced Learning*, Leeds, United Kingdom: University of Leeds.
- Mubarak, A. A., Cao, H. and Zhang, W. (2020). Prediction of students' early dropout based on their interaction logs in online learning environment. *Interactive Learning Environments*, 1-20.
- Nakahara, J., Yaegashi, K., Hisamatsu, S., Yamauchi, Y. (2005). iTree: Does the mobile phone encourage learners to be more involved in collaborative learning?. *Proceedings of The 2005 Conference on Computer Support for Collaborative Learning: Learning 2005: The Next 10 Years! (CSCL '05)*, International Society of the Learning Sciences, pp. 470-478.
- Nakić, J., Marangunić, N. and Granić, A. (2011). Learning styles and navigation patterns in web-based education. In *International Conference on Universal Access in Human-Computer Interaction*, pp. 587-596. Springer, Berlin, Heidelberg.

- Naranjo, D. M., Prieto, J. R., Moltó, G., Calatrava, A. (2019). A visual dashboard to track learning analytics for educational cloud computing. *Sensors*, 19(13), 1-15.
- Natekin, A. and Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- Nelder, J. A. and Wedderburn, R. W. M. (1972). Generalized Linear Models. *Journal of the Royal Statistical Society*, 135(3), 370-384. <https://doi.org/10.2307/2344614>
- Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., Garcia, A. L., Heredia, I., Malik, P., Hluchy, L. (2019). Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: A survey. *Artificial Intelligence Review*, 52, 77-124. <https://doi.org/10.1007/s10462-018-09679-z>
- Open University. (2018). OU Analyse. <https://analyse.kmi.open.ac.uk/> (Erişim tarihi: 05.01.2018).
- Ozturk, A. and Kumtepe, A. T. (2019). Exploring the learning behaviour patterns of open and distance students. *UNED*, Madrid (Spain), 156.
- Pallant, J. (2005). *SPSS survival manual: A step by step guide to data analysis using SPSS for Windows*. Australia: Australian Copyright.
- Park, Y. and Jo, I. H. (2015). Development of the learning analytics dashboard to support students' learning performance. *Journal of Universal Computer Science*, 21(1), 110.
- Park, Y. and Jo, I. H. (2019). Factors that affect the success of learning analytics dashboards. *Educational Technology Research and Development*, 67(6), 1547-1571.
- Peacock, S., Cowan, J., Irvine, L., Williams, J. (2020). An exploration into the importance of a sense of belonging for online learners. *International Review of Research in Open and Distributed Learning*, 21(2), 18-35.
- Pelletier, K., Brown, M., Brooks, D.C., McCormack, M., Reeves, J., Arbino, N., Bozkurt, A., Crawford, S., Czerniewicz, L., Gibson, R., Linder, K., Mason, J., Mondelli, V. (2021). *2021 EDUCAUSE horizon report teaching and learning edition*. Boulder, CO: EDU.
- Peña-Ayala, A. (2014). Educational data mining: A survey and a data mining-based analysis of recent Works. *Expert Systems with Applications*, 41, 1432-1462.
- Peña-Ayala, A. (2017). *Learning analytics: Fundamentals, applications, and trends. A view of the current state of the art to enhance e-learning*. Springer, Cham.

- Peña-Ayala, A. (2018). Learning analytics: A glance of evolution, status, and trends according to a proposed taxonomy. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(3). doi:10.1002/widm.1243
- Pijera Díaz, H. J., Santofimia Ruiz, J., Ruipérez-Valiente, J. A., Muñoz-Merino, P. J., Delgado Kloos, C. (2016). A demonstration of ANALYSE: A learning analytics tool for open edX. In *Proceedings of the Third ACM Conference on Learning@ Scale*, pp. 329-330.
- Podgorelec, V. and Kuhar, S. (2011). Taking advantage of education data: Advanced data analysis and reporting in virtual learning environments. *Elektronika ir Elektrotechnika*, 114(8), 111-116.
- Poon, L. K., Kong, S. C., Yau, T. S., Wong, M., Ling, M. H. (2017). Learning analytics for monitoring students participation online: Visualizing navigational patterns on learning management system. In *International Conference on Blended Learning*, pp. 166-176. Springer, Cham.
- Popenici, S. A. and Kerr, S. (2017). Exploring the impact of artificial intelligence on teaching and learning in higher education. *Research and Practice in Technology Enhanced Learning*, 12(1), 1-13.
- Powell, W. and Kusuma-Powell, O. (2011). *How to teach now: Five keys to personalized*
- Premlatha, K. R., Dharani, B. and Geetha, T. V. (2016). Dynamic learner profiling and automatic learner classification for adaptive e-learning environment. *Interactive Learning Environments*, 24(6), 1054-1075.
- Ramos-Soto, A., Vazquez-Barreiros, B., Bugarín, A., Gewerc, A., Barro, S. (2017). Evaluation of a data-to-text system for verbalizing a learning analytics dashboard. *International Journal of Intelligent Systems*, 32(2), 177-193.
- RapidMiner. (2021a). <https://bit.ly/3K0hCHo> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021b). <https://bit.ly/3zBWfaE> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021c). <https://bit.ly/3qVMm3r> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021d). <https://bit.ly/3JSk8PC> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021e). <https://bit.ly/3q44lFE> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021f). <https://bit.ly/3t2MnoP> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021g). <https://bit.ly/3G8iCqk> (Erişim tarihi: 12.09.2021).

- RapidMiner. (2021h). <https://bit.ly/3F3VvvX> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021k). <https://bit.ly/3n3oIkM> (Erişim tarihi: 12.09.2021).
- RapidMiner. (2021m). <https://bit.ly/3q44I30> (Erişim tarihi: 12.09.2021).
- Reddy, C. K. and Vinzamuri, B. (2014). Survey of partitional and hierarchical clustering algorithms. C. C. Aggarwal, C. K. Reddy (Editörler), *Data clustering: algorithms and applications* içinde (s. 87-110). NewYork: CRC.
- Rets, I., Herodotou, C., Bayer, V., Hlosta, M., Rienties, B. (2021). Exploring critical factors of the perceived usefulness of a learning analytics dashboard for distance university students. *International Journal of Educational Technology in Higher Education*, In-Press.
- Rezaei, M. S. and Montazer, G. A. (2016). An automatic adaptive grouping of learners in an e- learning environment based on fuzzy grafting and snap-drift clustering. *International Journal of Technology Enhanced Learning*, 8(2), 169-186.
- Riedel, C., Essa, A. and Bowen, K. (2017). 7 Things You Should Know About Artificial Intelligence in Teaching and Learning. *EDUCAUSE Learning Initiative (ELI)*.
- Rish, I. (2001). An empirical study of the naive Bayes classifier. In *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, 3 (22), 41-46.
- Roberts, L. D., Howell, J. A. and Seaman, K. (2017). Give me a customizable dashboard: Personalized learning analytics dashboards in higher education. *Technology, Knowledge and Learning*, 22(3), 317-333.
- Romero, C. and Ventura, S. (2013). Data mining in education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3(1), 12-27.
- Romero, C. and Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), e1355.
- Romero, C., Espejo, P. G., Zafra, A., Romero, J. R., Ventura, S. (2013). Web usage mining for predicting final marks of students that use Moodle courses. *Computer Applications in Engineering Education*, 21(1), 135-146.
- Romero, C., López, M. I., Luna, J. M., Ventura, S. (2013). Predicting students' final performance from participation in on-line discussion forums. *Computers & Education*, 68, 458-472.

- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53-65.
- Santos Odriozola, J. L., Klerkx, J. and Duval, E. (2013). Personal informatics for learning. In *CHI 2013 Workshop-Personal Informatics in the Wild: Hacking Habits for Health & Happiness*. Paris, France.
- SAS. (2021a). https://www.sas.com/tr_tr/insights/analytics/machine-learning.html (Erişim tarihi: 12.09.2021).
- SAS. (2021b). Data mining. https://www.sas.com/en_us/insights/analytics/data-mining.html (Erişim tarihi: 12.09.2021).
- SAS. (2021c). https://www.sas.com/en_in/insights/analytics/what-is-analytics.html (Erişim tarihi: 12.09.2021).
- Schumacher, C. and Ifenthaler, D. (2018). Features students really expect from learning analytics. *Computers in Human Behavior*, 78, 397-407.
- Schwendimann, B. A., Rodríguez-Triana, M. J., Vozniuk, A., Prieto, L. P., Boroujeni, M. S., Holzer, A., Gillet, D., Dillenbourg, P. (2017). Understanding learning at a glance: An overview of learning dashboard studies. *IEEE Transactions on Learning Technologies*, 10(1), 30-41.
- Sclater, N., Peasgood, A. and Mullan, J. (2016). Learning analytics in higher education. *Jisc.*, 8(2017), 176.
- Siemens, G. (2011). Learning analytics & knowledge. *1st International Conference on Learning Analytics and Knowledge*. Banff, AB, Canada.
- Siemens, G. (2013). Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, 57(10), 1380-1400.
- Siemens, G. and Baker, R. S. D. (2012). Learning analytics and educational data mining: towards communication and collaboration. In *Proceedings of The 2nd International Conference on Learning Analytics and Knowledge*, pp. 252-254.
- Siemens, G. and Long, P. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE review*, 46(5), 30.
- Simonson, M., Smaldino, S., Albright, M., Zvacek, S. (2012). *Teaching and learning at a distance: Foundations of distance education* (5th ed.). NY, Allyn & Bacon: Pearson Pub.

- Stöter, J., Bullen, M., Zawacki-Richter, O., von Prümmer, C. (2014). From the back door into the mainstream: The characteristics of lifelong learners. O. Zawacki-Richter and T. Anderson (Editörler), *Online Distance education: Towards a research agenda* içinde (pp. 421-458). Edmonton: AU Press.
- Tan, P. N., Steinbach, M. and Kumar, V. (2005). Association analysis: Basic concepts and algorithms. In *Introduction to Data Mining* (pp. 327–404). Boston, MA: Addison Wesley.
- Tan, P. N., Steinbach, M. and Kumar, V. (2014). *Introduction to data mining: Pearson new international edition*. London: Pearson Education Limited.
- Tan, P. N., Steinbach, M., Karpatne, A., Kumar, V. (2019). *Introduction to data mining* (2nd. Ed.). New York, NY: Pearson Education.
- Tlili, A., Denden, M., Affouneh, S., Salha, S. H., Cai, Z., Jemni, M., ... Zhu, L. (2021). Understanding Arab Students' Behavioral Patterns in an Online Course: An Explanatory Study Based on Hofstede's National Cultural Dimensions. *Sustainability*, 13(22), 12426.
- Uçar, H. (2016). *Uzaktan eğitimde motivasyon stratejilerinin öğrenenlerin ilgileri, motivasyonları, eylem yeterlikleri ve başarıları üzerine etkisi*. Yayınlanmamış Doktora Tezi. Eskişehir: Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü.
- Uçar, H. ve Kumtepe, A. (2016). Uzaktan eğitimde ARCS-V motivasyon tasarımı modelinin kullanımı. *AUAd*, 2(4), 37-54.
- Ulfa, S., Fattawi, I., Surahman, E., Yusuke, H. (2019). Investigating learners' perception of learning analytics dashboard to improve learning interaction in online learning system. *2019 5th International Conference on Education and Technology (ICET)*, IEEE, s. 49-54.
- Vellido, A., Castro, F. and Nebot, A. (2011). Clustering educational data. C. Romero, S. Ventura, M. Pechenizkiy, R. Baker (Editörler), *Handbook of educational data mining* içinde (s. 75-92). Boca Raton, FL: Chapman and Hall/CRC Press.
- Verbert, K., Duval, E., Klerkx, J., Govaerts, S., Santos, J. L. (2013). Learning analytics dashboard applications. *American Behavioral Scientist*, 57(10), 1500-1509.
- Verbert, K., Ochoa, X., De Croon, R., Dourado, R. A., De Laet, T. (2020). Learning analytics dashboards: The past, the present and the future. *Proceedings of The Tenth International Conference on Learning Analytics & Knowledge*, pp. 35-40.

- Wang, W., Guo, L., He, L., Wu, Y. J. (2019). Effects of social-interactive engagement on the dropout ratio in online learning: Insights from MOOC. *Behaviour & Information Technology*, 38(6), 621-636.
- Wartman, S. A. and Combs, C. D. (2018). Medical education must move from the information age to the age of artificial intelligence. *Academic Medicine*, 93(8), 1107-1109.
- Wendler, T. and Gröttrup, S. (2021). *Data Mining with SPSS Modeler*. Springer, Cham: Major Reference Books on Cluster Analysis.
- Willging, P. A. and Johnson, S. D. (2009). Factors that influence students decisions to dropout of online courses. *Journal of Asynchronous Learning Networks*, 13(3), 115-127.
- Xing, W., Guo, R., Petakovic, E., Goggins, S. (2015). Participation-based student final performance prediction model through interpretable Genetic Programming: Integrating learning analytics, educational data mining and theory. *Computers in Human Behavior*, 47, 168-181.
- Yoo, Y., Lee, H., Jo, I.-H., Park, Y. (2015). Educational dashboards for smart learning: review of case studies. *Emerging Issues in Smart Learning*, 145-155. https://doi.org/10.1007/978-3-662-44188-6_21
- You, J. W. (2016). Identifying significant indicators using LMS data to predict course achievement in online learning. *The Internet and Higher Education*, 29, 23-30.
- YÖK. (2021). Yükseköğretim bilgi yönetim sistemi. <https://istatistik.yok.gov.tr/> (Erişim tarihi: 12.09.2021).
- Yuk, M. and Diamond, S. (2014). *Data visualization for dummies*. New Jersey: John Wiley & Sons, Inc.
- Yukselturk, E. and Top, E. (2013). Exploring the link among entry characteristics, participation behaviors and course outcomes of online learners: An examination of learner profile using cluster analysis. *British Journal of Educational Technology*, 44(5), 716-728.
- Zaccone, G. (2016). *Getting started with TensorFlow*. Birmingham: Packt Publishing.
- Zacharis, N. Z. (2015). A multivariate approach to predicting student outcomes in webenabled blended learning courses. *The Internet and Higher Education*, 27(1), 44-53.

- Zafra, A., Romero, C. and Ventura, S. (2011). Multiple instance learning for classifying students in learning management systems. *Expert Systems with Applications*, 38(12), 15020-15031.
- Zawacki-Richter, O., Marín, V. I., Bond, M., Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education-Where are the educators?. *International Journal of Educational Technology in Higher Education*, 16(1), 1-27.
- Zhang, X. D. (2020). Machine learning. *A matrix algebra approach to artificial intelligence içinde* (pp. 223-440). Springer, Singapore.
- Zhao, Q. and Bhowmick, S. S. (2003). *Association rule mining: A survey*. Nanyang Technological University, Singapore, 135.
- Zhu, X. and Goldberg, A. B. (2009). Introduction to semi-supervised learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 3(1), 1-130.
- Ziebarth, S., Chounta, I. A. and Hoppe, H. U. (2015). Resource access patterns in exam preparation activities. In *Design for Teaching and Learning in a Networked World* (pp. 497-502). Springer, Cham.

EKLER

EK-1. CARMA Algoritması ile Elde Edilen Birliklik Kuralları

10 fields

	Consequent	Antecedent	Support %	Confidence %
1	Çıkış Soruları	Deneme Soruları and Ünite Metni	21.993	94.319
2	Çıkış Soruları	Deneme Soruları and Ünite Özet	23.292	93.937
3	Çıkış Soruları	Ünite Metni and Ünite Özet and Video	23.733	91.999
4	Çıkış Soruları	Ses Tabanlı Malzemeler and Ünite Metni and Ünite Özet	21.863	91.999
5	Çıkış Soruları	Deneme Soruları	32.398	90.921
6	Ünite Özet	Çıkış Soruları and Ses Tabanlı Malzemeler and Ünite Metni	22.146	90.823
7	Ünite Özet	Çıkış Soruları and Ünite Metni and Video	24.169	90.34
8	Çıkış Soruları	Ünite Metni and Video	26.803	90.171
9	Çıkış Soruları	Ses Tabanlı Malzemeler and Ünite Metni	24.632	89.909
10	Çıkış Soruları	Ses Tabanlı Malzemeler and Ünite Özet	27.829	89.76
11	Çıkış Soruları	Ünite Özet and Video	30.791	89.615
12	Çıkış Soruları	Ses Tabanlı Malzemeler and Video	23.563	89.531
13	Ünite Özet	Çıkış Soruları and Ders Kitabı and Ünite Metni	29.253	89.453
14	Çıkış Soruları	Ders Kitabı and Ünite Metni and Ünite Özet	29.385	89.057
15	Ünite Özet	Ses Tabanlı Malzemeler and Ünite Metni	24.632	88.759
16	Ünite Özet	Ünite Metni and Video	26.803	88.544
17	Çıkış Soruları	Canlı Ders Kayıtları	24.129	88.266
18	Çıkış Soruları	Ünite Metni and Ünite Özet	43.249	87.608
19	Çıkış Soruları	Ders Kitabı and Video	25.792	87.309
20	Ünite Özet	Çıkış Soruları and Ünite Metni	43.434	87.234
21	Ünite Özet	Ders Kitabı and Ünite Metni	33.981	86.476
22	Çıkış Soruları	Ders Kitabı and Ünite Özet	37.435	86.234
23	Çıkış Soruları	Ders Kitabı and Ünite Metni	33.981	86.093
24	Çıkış Soruları	Ders Kitabı and Ses Tabanlı Malzemeler	24.585	85.784
25	Ünite Özet	Ses Tabanlı Malzemeler and Video	23.563	85.059

EK-2. FP-Growth Algoritması ile Elde Edilen Birliktelik Kuralları

No.	Premises	Conclusion	Support ↓	Confidence	LaPlace	Gain	p-s	Lift	Convic...
6	Çıkmış Sınav Soruları, Ünite Metni	Ünite Özeti	0.379	0.872	0.961	-0.490	0.111	1.413	2.998
8	Ünite Özeti, Ünite Metni	Çıkmış Sınav Soruları	0.379	0.876	0.963	-0.486	0.038	1.111	1.705
4	Ünite Özeti, Ders Kitabı	Çıkmış Sınav Soruları	0.323	0.862	0.963	-0.426	0.028	1.093	1.535
22	Deneme Sınavı	Çıkmış Sınav Soruları	0.295	0.909	0.978	-0.353	0.039	1.153	2.328
5	Ders Kitabı, Ünite Metni	Ünite Özeti	0.294	0.865	0.966	-0.386	0.084	1.401	2.831
3	Ders Kitabı, Ünite Metni	Çıkmış Sınav Soruları	0.293	0.861	0.965	-0.387	0.025	1.092	1.520
15	Ünite Özeti, Video	Çıkmış Sınav Soruları	0.276	0.896	0.976	-0.340	0.033	1.136	2.035
12	Ünite Özeti, Ders Kitabı, Ünite Metni	Çıkmış Sınav Soruları	0.262	0.891	0.975	-0.326	0.030	1.129	1.931
13	Çıkmış Sınav Soruları, Ders Kitabı, Ünite Metni	Ünite Özeti	0.262	0.895	0.976	-0.323	0.081	1.449	3.630
16	Ünite Özeti, Ses Tabanlı Malzemeler	Çıkmış Sınav Soruları	0.250	0.898	0.978	-0.307	0.030	1.138	2.064
19	Ünite Metni, Video	Çıkmış Sınav Soruları	0.242	0.902	0.979	-0.294	0.030	1.143	2.150
25	Ünite Özeti, Deneme Sınavı	Çıkmış Sınav Soruları	0.238	0.939	0.988	-0.268	0.038	1.191	3.486
10	Ünite Metni, Video	Ünite Özeti	0.237	0.885	0.976	-0.299	0.072	1.435	3.342
7	Ders Kitabı, Video	Çıkmış Sınav Soruları	0.225	0.873	0.974	-0.291	0.022	1.107	1.665
17	Ünite Metni, Ses Tabanlı Malzemeler	Çıkmış Sınav Soruları	0.221	0.899	0.980	-0.271	0.027	1.140	2.094
11	Ünite Metni, Ses Tabanlı Malzemeler	Ünite Özeti	0.219	0.888	0.978	-0.274	0.067	1.438	3.405
20	Çıkmış Sınav Soruları, Ünite Metni, Video	Ünite Özeti	0.218	0.903	0.981	-0.265	0.069	1.464	3.963
24	Ünite Özeti, Ünite Metni, Video	Çıkmış Sınav Soruları	0.218	0.920	0.985	-0.256	0.031	1.167	2.641
9	Canlı Ders Kayıtları	Çıkmış Sınav Soruları	0.213	0.883	0.977	-0.270	0.023	1.119	1.801
14	Video, Ses Tabanlı Malzemeler	Çıkmış Sınav Soruları	0.211	0.895	0.980	-0.260	0.025	1.135	2.019
2	Ders Kitabı, Ses Tabanlı Malzemeler	Çıkmış Sınav Soruları	0.211	0.858	0.972	-0.281	0.017	1.088	1.487
26	Ünite Metni, Deneme Sınavı	Çıkmış Sınav Soruları	0.207	0.943	0.990	-0.232	0.034	1.196	3.720
21	Çıkmış Sınav Soruları, Ünite Metni, Ses Tabanlı ...	Ünite Özeti	0.201	0.908	0.983	-0.242	0.064	1.472	4.171
23	Ünite Özeti, Ünite Metni, Ses Tabanlı Malzemeler	Çıkmış Sınav Soruları	0.201	0.920	0.986	-0.236	0.029	1.167	2.641
1	Video, Ses Tabanlı Malzemeler	Ünite Özeti	0.200	0.851	0.972	-0.271	0.055	1.378	2.562

EK-3. GBT Algoritması Tahmin Modeli Sonucu

Gradient Boosted Model

Model Metrics Type: Multinomial

Description: N/A

model id: rm-h2o-model-gradient_boosted_trees-127591

frame id: rm-h2o-frame-gradient_boosted_trees-127591

MSE: 0.22729406

RMSE: 0.47675365

R²: 0.88111365

logloss: 0.6325018

mean_per_class_error: 0.45681852

hit ratios: [0.73135835, 0.9037681, 0.97425795, 0.9974957, 1.0]

CM: Confusion Matrix (Row labels: Actual class; Column labels: Predicted class):

	A	B	C	D	F	Error	Rate
A	1187	1689	5	0	0	0.5880	1,694 / 2,881
B	618	8389	2193	0	14	0.2519	2,825 / 11,214
C	130	3428	7009	3	767	0.3818	4,328 / 11,337
D	7	429	1595	109	554	0.9595	2,585 / 2,694
F	0	261	2143	2	20979	0.1029	2,406 / 23,385
Totals	1942	14196	12945	114	22314	0.2686	13,838 / 51,511

Variable Importances:

	Variable	Relative Importance	Scaled Importance	Percentage
	SinavaGirmeOrani	164873.359375	1.000000	0.635875
	MIDTERMGRADE	80051.281250	0.485532	0.308738
	fill_denemeort	3408.984619	0.020676	0.013148
	Yas	3205.158691	0.019440	0.012361
	ToplamFaaliyetSayisi_Ders	2655.802490	0.016108	0.010243
	OturumActigiGunSayisi_Ders	1314.290405	0.007972	0.005069
	GunlukOrtalamaOrurumAcmaSayisi_Ders	1211.866089	0.007350	0.004674
	CikmisSinavSorulari	1130.026978	0.006854	0.004358
	OturumSayisi_Ders	1054.622314	0.006397	0.004067
	Sure_Ders_dk	280.026672	0.001698	0.001080
	DonemHaftasi = Yok	100.470512	0.000609	0.000387

Model Summary:

Number of Trees	Number of Internal Trees	Model Size in Bytes	Min. Depth	Max. Depth	Mean Depth	Min. Leaves	Max. Leaves	Mean Leaves	
150		750	318784	5	5	5.00000	12	32	29.11067

Scoring History:

Timestamp	Duration	Number of Trees	Training RMSE	Training LogLoss	Training Classification Error
2021-12-25 21:34:03	1.106 sec	0	0.80000	1.60944	0.68960
2021-12-25 21:34:03	1.417 sec	1	0.78658	1.54532	0.28192
2021-12-25 21:34:03	1.543 sec	2	0.77354	1.48794	0.28196
2021-12-25 21:34:03	1.745 sec	3	0.76087	1.43613	0.28041
2021-12-25 21:34:04	1.919 sec	4	0.74860	1.38900	0.28041
2021-12-25 21:34:04	2.117 sec	5	0.73670	1.34586	0.28033
2021-12-25 21:34:04	2.299 sec	6	0.72518	1.30610	0.28021
2021-12-25 21:34:04	2.494 sec	7	0.71406	1.26937	0.28023
2021-12-25 21:34:04	2.721 sec	8	0.70332	1.23532	0.28017
2021-12-25 21:34:05	2.910 sec	9	0.69298	1.20368	0.28011

2021-12-25 21:34:06	4.302 sec	16	0.63142	1.03267	0.27848
2021-12-25 21:34:06	4.496 sec	17	0.62410	1.01375	0.27839
2021-12-25 21:34:06	4.822 sec	18	0.61710	0.99587	0.27843
2021-12-25 21:34:07	5.022 sec	19	0.61045	0.97902	0.27839
2021-12-25 21:34:11	9.142 sec	42	0.52403	0.75997	0.27623
2021-12-25 21:34:15	13.288 sec	65	0.49778	0.68584	0.27431

EK-4. A Harf Notu için GBT Algoritması ile Elde Edilen Ağaç Açıklaması

Tree

```
fill_denemeort < 0.555
| MIDTERMGRADE < 0.918
| | SinavaGirmeOrani < 0.500
| | | MIDTERMGRADE < 0.693
| | | | Yas < 0.083: -0.024 {}
| | | | Yas >= 0.083: -0.024 {}
| | | MIDTERMGRADE >= 0.693: -0.024 {}
| | SinavaGirmeOrani >= 0.500
| | | MIDTERMGRADE < 0.861
| | | | MIDTERMGRADE < 0.821: -0.015 {}
| | | | MIDTERMGRADE >= 0.821: -0.013 {}
| | | MIDTERMGRADE >= 0.861
| | | | ToplamFaaliyetSayisi_Ders < 0.005: 0.018 {}
| | | | ToplamFaaliyetSayisi_Ders >= 0.005: -0.003 {}
| | MIDTERMGRADE >= 0.918
| | | GunlukOrtalamaOrurumAcmaSayisi_Ders < 0.206
| | | | ToplamFaaliyetSayisi_Ders < 0.003: -0.009 {}
| | | | ToplamFaaliyetSayisi_Ders >= 0.003: 0.029 {}
| | | GunlukOrtalamaOrurumAcmaSayisi_Ders >= 0.206
| | | | CikmisSinavSorulari < 0.033
| | | | | CikmisSinavSorulari < 0.018: -0.018 {}
| | | | | CikmisSinavSorulari >= 0.018: -0.034 {}
| | | | CikmisSinavSorulari >= 0.033
| | | | | ToplamFaaliyetSayisi_Ders < 0.016: -0.007 {}
| | | | | ToplamFaaliyetSayisi_Ders >= 0.016: 0.017 {}
fill_denemeort >= 0.555
| OturumActigiGunSayisi_Ders < 0.022
| | ToplamFaaliyetSayisi_Ders < 0.009
| | | fill_denemeort < 0.988
| | | | CikmisSinavSorulari < 0.005: -0.000 {}
| | | | CikmisSinavSorulari >= 0.005: -0.006 {}
| | | fill_denemeort >= 0.988
| | | | CikmisSinavSorulari < 0.019: 0.003 {}
| | | | CikmisSinavSorulari >= 0.019: 0.017 {}
| | | ToplamFaaliyetSayisi_Ders >= 0.009: -0.024 {}
| | OturumActigiGunSayisi_Ders >= 0.022
| | | Yas < 0.325
| | | | Yas < 0.174
| | | | | MIDTERMGRADE < 0.914: -0.000 {}
| | | | | MIDTERMGRADE >= 0.914: 0.004 {}
| | | | Yas >= 0.174
| | | | | CikmisSinavSorulari < 0.029: 0.007 {}
| | | | | CikmisSinavSorulari >= 0.029: 0.001 {}
| | | Yas >= 0.325
| | | | ToplamFaaliyetSayisi_Ders < 0.009
| | | | | CikmisSinavSorulari < 0.018: 0.002 {}
| | | | | CikmisSinavSorulari >= 0.018: -0.006 {}
| | | | ToplamFaaliyetSayisi_Ders >= 0.009
| | | | | ToplamFaaliyetSayisi_Ders < 0.010: 0.013 {}
| | | | | ToplamFaaliyetSayisi_Ders >= 0.010: 0.001 {}
```

EK-5. B Harf Notu için GBT Algoritması ile Elde Edilen Ağaç Açıklaması

Tree

```
fill_denemeort < 0.808
|   fill_denemeort < 0.782
|   |   OturumActigiGunSayisi_Ders < 0.135
|   |   |   CikmisSinavSorulari < 0.049
|   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders < 0.438: 0.000 {}
|   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders >= 0.438: 0.023 {}
|   |   |   |   CikmisSinavSorulari >= 0.049
|   |   |   |   |   MIDTERMGRADE < 0.453: 0.003 {}
|   |   |   |   |   MIDTERMGRADE >= 0.453: -0.005 {}
|   |   |   |   OturumActigiGunSayisi_Ders >= 0.135
|   |   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders < 0.225
|   |   |   |   |   |   MIDTERMGRADE < 0.891: 0.005 {}
|   |   |   |   |   |   MIDTERMGRADE >= 0.891: 0.032 {}
|   |   |   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders >= 0.225
|   |   |   |   |   |   |   Yas < 0.262: 0.004 {}
|   |   |   |   |   |   |   Yas >= 0.262: -0.003 {}
|   |   fill_denemeort >= 0.782
|   |   |   Yas < 0.143
|   |   |   |   CikmisSinavSorulari < 0.063
|   |   |   |   |   MIDTERMGRADE < 0.547: 0.031 {}
|   |   |   |   |   MIDTERMGRADE >= 0.547: 0.002 {}
|   |   |   |   |   CikmisSinavSorulari >= 0.063: -0.015 {}
|   |   |   |   Yas >= 0.143
|   |   |   |   |   Yas < 0.174
|   |   |   |   |   |   ToplamFaaliyetSayisi_Ders < 0.004: -0.039 {}
|   |   |   |   |   |   ToplamFaaliyetSayisi_Ders >= 0.004: -0.018 {}
|   |   |   |   |   |   Yas >= 0.174
|   |   |   |   |   |   |   CikmisSinavSorulari < 0.011: 0.003 {}
|   |   |   |   |   |   |   CikmisSinavSorulari >= 0.011: -0.013 {}
|   fill_denemeort >= 0.808
|   |   OturumSayisi_Ders < 0.120
|   |   |   ToplamFaaliyetSayisi_Ders < 0.018
|   |   |   |   ToplamFaaliyetSayisi_Ders < 0.008
|   |   |   |   |   OturumActigiGunSayisi_Ders < 0.092: 0.001 {}
|   |   |   |   |   OturumActigiGunSayisi_Ders >= 0.092: 0.004 {}
|   |   |   |   |   ToplamFaaliyetSayisi_Ders >= 0.008
|   |   |   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders < 0.338: 0.006 {}
|   |   |   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders >= 0.338: -0.013 {}
|   |   |   |   |   ToplamFaaliyetSayisi_Ders >= 0.018
|   |   |   |   |   |   fill_denemeort < 0.850: -0.029 {}
|   |   |   |   |   |   fill_denemeort >= 0.850
|   |   |   |   |   |   |   ToplamFaaliyetSayisi_Ders < 0.027: -0.013 {}
|   |   |   |   |   |   |   ToplamFaaliyetSayisi_Ders >= 0.027: 0.015 {}
|   |   |   OturumSayisi_Ders >= 0.120
|   |   |   |   OturumSayisi_Ders < 0.193
|   |   |   |   |   OturumSayisi_Ders < 0.182
|   |   |   |   |   |   OturumSayisi_Ders < 0.172: -0.005 {}
|   |   |   |   |   |   OturumSayisi_Ders >= 0.172: 0.007 {}
|   |   |   |   |   |   OturumSayisi_Ders >= 0.182
|   |   |   |   |   |   |   MIDTERMGRADE < 0.711: -0.005 {}
|   |   |   |   |   |   |   MIDTERMGRADE >= 0.711: -0.027 {}
|   |   |   |   |   OturumSayisi_Ders >= 0.193
|   |   |   |   |   |   fill_denemeort < 0.817
|   |   |   |   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders < 0.257: 0.012 {}
|   |   |   |   |   |   |   GunlukOrtalamaOrurumAcmaSayisi_Ders >= 0.257: 0.036 {}
|   |   |   |   |   |   |   fill_denemeort >= 0.817
|   |   |   |   |   |   |   |   OturumActigiGunSayisi_Ders < 0.281: 0.006 {}
|   |   |   |   |   |   |   |   OturumActigiGunSayisi_Ders >= 0.281: -0.009 {}
```


EK-7. D Harf Notu için GBT Algoritması ile Elde Edilen Ağaç Açıklaması

Tree

```
MIDTERMGRADE < 0.467
| MIDTERMGRADE < 0.455
| | CikmisSinavSorulari < 0.033
| | | CikmisSinavSorulari < 0.011
| | | | OturumActigiGunSayisi_Ders < 0.064: 0.000 {}
| | | | OturumActigiGunSayisi_Ders >= 0.064: -0.010 {}
| | | | CikmisSinavSorulari >= 0.011
| | | | | OturumSayisi_Ders < 0.065: 0.002 {}
| | | | | OturumSayisi_Ders >= 0.065: 0.014 {}
| | | CikmisSinavSorulari >= 0.033
| | | | OturumSayisi_Ders < 0.099
| | | | | fill_denemeort < 0.016: 0.007 {}
| | | | | fill_denemeort >= 0.016: -0.007 {}
| | | | | OturumSayisi_Ders >= 0.099
| | | | | OturumSayisi_Ders < 0.110: 0.026 {}
| | | | | OturumSayisi_Ders >= 0.110: -0.002 {}
| MIDTERMGRADE >= 0.455
| | Yas < 0.189
| | | ToplamFaaliyetSayisi_Ders < 0.002
| | | | DonemHaftasi = Yok < 0.500: 0.016 {}
| | | | DonemHaftasi = Yok >= 0.500: -0.011 {}
| | | | ToplamFaaliyetSayisi_Ders >= 0.002
| | | | | ToplamFaaliyetSayisi_Ders < 0.005: -0.026 {}
| | | | | ToplamFaaliyetSayisi_Ders >= 0.005: -0.025 {}
| | | Yas >= 0.189
| | | | CikmisSinavSorulari < 0.040
| | | | | OturumActigiGunSayisi_Ders < 0.022: 0.024 {}
| | | | | OturumActigiGunSayisi_Ders >= 0.022: -0.010 {}
| | | | CikmisSinavSorulari >= 0.040: 0.111 {}
MIDTERMGRADE >= 0.467
| Yas < 0.446
| | MIDTERMGRADE < 0.806
| | | CikmisSinavSorulari < 0.049
| | | | ToplamFaaliyetSayisi_Ders < 0.005: -0.000 {}
| | | | ToplamFaaliyetSayisi_Ders >= 0.005: -0.009 {}
| | | | CikmisSinavSorulari >= 0.049
| | | | MIDTERMGRADE < 0.570: 0.018 {}
| | | | MIDTERMGRADE >= 0.570: 0.002 {}
| | | MIDTERMGRADE >= 0.806
| | | | SinavaGirmeOrani < 0.650
| | | | | MIDTERMGRADE < 0.832: -0.024 {}
| | | | | MIDTERMGRADE >= 0.832: 0.025 {}
| | | | SinavaGirmeOrani >= 0.650
| | | | | DonemHaftasi = Yok < 0.500: -0.012 {}
| | | | | DonemHaftasi = Yok >= 0.500: 0.000 {}
| Yas >= 0.446
| | MIDTERMGRADE < 0.506
| | | OturumActigiGunSayisi_Ders < 0.064
| | | | SinavaGirmeOrani < 0.650: -0.024 {}
| | | | SinavaGirmeOrani >= 0.650: -0.026 {}
| | | | OturumActigiGunSayisi_Ders >= 0.064
| | | | | ToplamFaaliyetSayisi_Ders < 0.005: 0.046 {}
| | | | | ToplamFaaliyetSayisi_Ders >= 0.005: -0.015 {}
| | | MIDTERMGRADE >= 0.506
| | | | OturumActigiGunSayisi_Ders < 0.050
| | | | | MIDTERMGRADE < 0.532: 0.019 {}
| | | | | MIDTERMGRADE >= 0.532: -0.004 {}
| | | | OturumActigiGunSayisi_Ders >= 0.050
| | | | | MIDTERMGRADE < 0.832: -0.022 {}
| | | | | MIDTERMGRADE >= 0.832: 0.000 {}
```

EK-8. F Harf Notu için GBT Algoritması ile Elde Edilen Ağaç Açıklaması

Tree

```
SinavaGirmeOrani < 0.500
| MIDTERMGRADE < 0.243
| | Yas < 0.083
| | | Yas < 0.068
| | | | fill_denemeort < 0.461: 0.024 {}
| | | | fill_denemeort >= 0.461: 0.024 {}
| | | | Yas >= 0.068
| | | | fill_denemeort < 0.305: 0.024 {}
| | | | fill_denemeort >= 0.305: 0.024 {}
| | | Yas >= 0.083
| | | | fill_denemeort < 0.242
| | | | | Yas < 0.371: 0.024 {}
| | | | | Yas >= 0.371: 0.024 {}
| | | | fill_denemeort >= 0.242
| | | | | GunlukOrtalamaOrurumAcmaSayisi_Ders < 0.328: 0.024 {}
| | | | | GunlukOrtalamaOrurumAcmaSayisi_Ders >= 0.328: 0.024 {}
| | MIDTERMGRADE >= 0.243
| | | MIDTERMGRADE < 0.831
| | | | MIDTERMGRADE < 0.745
| | | | | MIDTERMGRADE < 0.409: 0.024 {}
| | | | | MIDTERMGRADE >= 0.409: 0.024 {}
| | | | | MIDTERMGRADE >= 0.745
| | | | | ToplamFaaliyetSayisi_Ders < 0.009: 0.024 {}
| | | | | ToplamFaaliyetSayisi_Ders >= 0.009: 0.024 {}
| | | | MIDTERMGRADE >= 0.831
| | | | | OturumSayisi_Ders < 0.015: -0.024 {}
| | | | | OturumSayisi_Ders >= 0.015
| | | | | fill_denemeort < 0.717: -0.024 {}
| | | | | fill_denemeort >= 0.717: -0.024 {}
SinavaGirmeOrani >= 0.500
| SinavaGirmeOrani < 0.850
| | Yas < 0.342
| | | Yas < 0.311
| | | | Yas < 0.250: -0.003 {}
| | | | Yas >= 0.250: 0.005 {}
| | | | Yas >= 0.311
| | | | CikmisSinavSorulari < 0.005: -0.023 {}
| | | | CikmisSinavSorulari >= 0.005: 0.005 {}
| | | Yas >= 0.342
| | | | DonemHaftasi = Yok < 0.500
| | | | | Yas < 0.476: -0.013 {}
| | | | | Yas >= 0.476: -0.002 {}
| | | | | DonemHaftasi = Yok >= 0.500
| | | | | Yas < 0.417: 0.013 {}
| | | | | Yas >= 0.417: 0.033 {}
| | SinavaGirmeOrani >= 0.850
| | | MIDTERMGRADE < 0.008
| | | | Yas < 0.082
| | | | | CikmisSinavSorulari < 0.004: -0.001 {}
| | | | | CikmisSinavSorulari >= 0.004: -0.014 {}
| | | | | Yas >= 0.082
| | | | | OturumActigiGunSayisi_Ders < 0.050: 0.009 {}
| | | | | OturumActigiGunSayisi_Ders >= 0.050: -0.022 {}
| | | | MIDTERMGRADE >= 0.008
| | | | | fill_denemeort < 0.039
| | | | | | Yas < 0.297: -0.007 {}
| | | | | | Yas >= 0.297: 0.011 {}
| | | | | fill_denemeort >= 0.039
| | | | | MIDTERMGRADE < 0.059: 0.018 {}
| | | | | MIDTERMGRADE >= 0.059: -0.001 {}
```

EK-9. DL Algoritması Tahmin Modeli Sonucu

Deep Learning Model

```
Model Metrics Type: Multinomial
Description: Metrics reported on temporary training frame with 9942 samples
model id: rm-h2o-model-deep_learning-30702
frame id: rm-h2o-frame-deep_learning-30702.temporary.sample.22.844
MSE: 0.2361677
RMSE: 0.48597088
R^2: 0.8761019
logloss: 0.6777122
mean_per_class_error: 0.47139096
hit ratios: [0.7109234, 0.89519215, 0.9699256, 0.99738485, 1.0]
CM: Confusion Matrix (Row labels: Actual class; Column labels: Predicted class):
      A   B   C   D   F   Error   Rate
A  249  318   0   0   0  0.5608  318 / 567
B  211 1450  461   0   1  0.3170  673 / 2,123
C   45   664 1418   0  82  0.3581  791 / 2,209
D    1    78   378   0  91  1.0000  548 / 548
F    0    46   498   0 3951  0.1210  544 / 4,495
Totals 506 2556 2755   0 4125  0.2891 2,874 / 9,942
Variable Importances:
      Variable Relative Importance Scaled Importance Percentage
      Ara Sinav Puani 1.000000 1.000000 0.174413
      Sinava Girme Orani 0.984405 0.984405 0.171693
      Toplam Faaliyet Sayisi_BIL102U 0.708017 0.708017 0.123487
      Canli Ders Kayitlari 0.696791 0.696791 0.121529
      Ocurum Sayisi_BIL102U 0.660376 0.660376 0.115278
      Ders Kitabi 0.657328 0.657328 0.114646
      Video 0.655515 0.655515 0.114330
      Yag 0.371094 0.371094 0.064724
Status of Neuron Layers (predicting Harf Notu, 5-class classification, multinomial distribution, CrossEntropy loss, 27,205 weights/biases, 328.1 KB, 87,568 training samples, mini-batch size 1):
Layer Units Type Dropout L1 L2 Mean Rate Rate RMS Momentum Mean Weight Weight RMS Mean Bias Bias RMS
1 8 Input 0.00 0 0.000010 0.000000 0.009144 0.006471 0.000000 -0.001513 0.083448 -0.005717 0.047583
2 200 ExpRectifier 0 0.000010 0.000000 0.067781 0.049130 0.000000 0.000505 0.067856 -0.000812 0.103823
3 100 ExpRectifier 0 0.000010 0.000000 0.019801 0.014462 0.000000 0.004028 0.111837 -0.052371 0.235849
4 50 ExpRectifier 0 0.000010 0.000000 0.004209 0.002088 0.000000 0.009363 0.376525 -0.219445 0.122289
5 5 Softmax 0.000010 0.000000
Scoring History:
Timestamp Duration Training Speed Epochs Iterations Samples Training RMSE Training LogLoss Training r2 Training Classification Error
2021-12-26 04:16:55 0.000 sec 1179 obs/sec 1.00000 0 0.000000 NaN NaN NaN
2021-12-26 04:17:32 37.655 sec 1190 obs/sec 2.00000 1 43784.000000 0.48597 0.67771 0.87610 0.28908
2021-12-26 04:18:09 1 min 14.500 sec 1190 obs/sec 2.00000 2 87568.000000 0.48971 0.69766 0.86952 0.30477
2021-12-26 04:18:10 1 min 14.910 sec 1190 obs/sec 2.00000 2 87568.000000 0.48597 0.67771 0.87610 0.28908
H2O version: 3.30.0.1-rm9.8.1
```

EK-10. Performans Değerlendirme Paneline Yönelik Öğrenen Görüşlerinin Belirlenmesi Anketi

Performans Değerlendirme Paneli Memnuniyet Anketi

Değerli öğrencimiz,

Bahar döneminde Temel Bilgi Teknolojileri II dersinde aşağıda görseli yer alan Performans Değerlendirme Paneli sizlere sunulmuştur. Bu panelde öğrenme sürecinize yönelik bilgiler ve ders sorumlusu tarafından gönderilen mesajlar yer almaktadır.

Bu anket, Performans Değerlendirme Paneline yönelik görüşlerinizin ve memnuniyet durumunuzun belirlenmesi amacıyla hazırlanmıştır. Ankete katılımınız gönüllülük esasına dayalıdır. Bize vereceğiniz bilgilerde samimi ve doğru cevaplar vermeniz doğru geliştirme çalışmalarının yapılabilmesi için önemlidir. Vereceğiniz bilgiler sadece araştırma-geliştirme amaçlı kullanılacaktır. Yanıtlar kimse ile paylaşılmayacak olup ankete katılmayı istememeniz durumunda ankette ayrılabiliyorsunuz.

Anketi tamamlama süresi yaklaşık 3 dakikadır. Ankete katılmayı kabul ettiğiniz için teşekkür ederim.

Prof.Dr. Tefvik Volkan YÜZER
Anadolu Üniversitesi Açıköğretim Fakültesi

* Gerekli

Performans Değerlendirme Paneli



1. Paneldeki verilerinizi hangi sıklıkla incelediniz? *

Yalnızca bir şıkkı işaretleyin.

- Hiç inceledim.
- Bazen inceledim.
- Sisteme her girdiğimde inceledim.

2. Öğretim elemanı tarafından gönderilen mesajları hangi sıklıkla okudunuz? *

Yalnızca bir şıkkı işaretleyin.

- Mesajları hiç dikkate almadım.
- Zaman zaman göz attım.
- Mesajları düzenli olarak okudum.

EK-10. Performans Değerlendirme Paneline Yönelik Öğrenen Görüşlerinin Belirlenmesi Anketi (Devam)

3. Aşağıda Performans Değerlendirme Paneline yönelik verilen görüşlere katılma derecenizi işaretleyiniz. *

Her satırda yalnızca bir şıkki işaretleyin.

	Hiç Katılmıyorum	Katılmıyorum	Kararsızım	Katılıyorum	Kesinlikle Katılıyorum
Mesajlarda adımın yer alması öğretim elemanı tarafından önemsendiğimi hissettirdi.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Mesaj sıklığı yeterliydi.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Mesaj içerikleri anlaşılırdı.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Öğretim elemanından geribildirim almak motivasyonumu artırdı.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Öğretim elemanından mesaj almak derse katılımımı artırdı.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Öğretim elemanından mesaj almak öğrenme sürecimde yalnız olmadığımı hissettirdi.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Aldığım geribildirimler öğrenme sürecime destek oldu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Aldığım geribildirimler başarıımı artırdı.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Bu uygulamanın diğer derslerimde de olmasını isterim.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Uygulamayı kullandığım için memnunum.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Tüm Açıköğretim öğrencilerinin kullanması gerektiğini düşünüyorum.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panelde yer alan bilgileri kolayca anlayabildim.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Dönem başında sunulan tanıtım videosu, paneli kullanmama yardımcı oldu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Tüm bilgilere tek bir sayfadan erişebilmek ilerleme durumumu takip etmemi kolaylaştırdı.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panel öğrenme sürecimi destekleyen bilgileri içeriyordu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panelde yer alan bilgiler benim için önemliydi.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panel zaman yönetimine destek oldu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Paneldeki sayıların ve yüzdelerin ne anlama geldiğini anladım.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Çalışma durumumu panelden takip edebildim.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Durumumu, sınıfın genel çalışma durumu ile kolayca karşılaştırdım.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panel sayesinde eKampüs'e daha sık giriş yaptım.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panel öğrenme hedeflerime ulaşmama yardımcı oldu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Panel öğrenme sürecimde motivasyonumu artırdı.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Paneldeki bilgilere dayanarak kendi öğrenme sürecimi planlayabildim.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Paneldeki bilgiler çalışma alışkanlıklarımı düzenlememe yardımcı oldu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

EK-10. Performans Deęerlendirme Paneline Yönelik Öęrenen Görüşlerinin Belirlenmesi Anketi (Devam)

4. Performans Deęerlendirme Paneline yönelik eklemek istedięiniz görüşleriniz ya da önerileriniz varsa lütfen açıklayınız.

5. Kullanıcı Kodu

Bu alan kullanıcı bilgilerinizi içermektedir. Sadece analiz süreçlerinde kullanılacaktır. Deęiştirmeden bırakınız.

Bu içerik Google tarafından oluşturulmamış veya onaylanmamıştır.

Google Formlar

EK-11. Etik Kurul İzin Belgesi

Evrak Kayıt Tarihi: 15.02.2018 Protokol No: 19453

Tarih: 26.02.2018



ANADOLU ÜNİVERSİTESİ
SOSYAL VE BEŞERİ BİLİMLER BİLİMSEL ARAŞTIRMA VE YAYIN ETİĞİ KURULU
KARAR BELGESİ

ÇALIŞMANIN TÜRÜ:	TÜBİTAK Projesi
KONU:	Sosyal Bilimler
BAŞLIK:	Öğrenme Yönetim Sisteminde Öğrenen Profillerinin Belirlenmesi, Akademik Başarının Tahmin Edilmesi ve Öneri Sisteminin Etkilerinin Belirlenmesi
PROJE/TEZ YÜRÜTÜCÜSÜ:	Doç. Dr. Alper Tolga KUMTEPE
TEZ YAZARI:	-
ALT KOMİSYON GÖRÜŞÜ:	-
KARAR:	Olumlu

EK-12. Kurum İzin Belgesi

EK-2. Anket Uygulama Dilekçesi

05/03/2018

AÇIKÖĞRETİM FAKÜLTESİ DEKANLIĞI
(İstatistik Bilgi Edinme ve Değerlendirme Birimine)

"Öğrenme Yönetim Sisteminde Öğrenen Profillerinin Belirlenmesi, Akademik Başarının Tahmin Edilmesi ve Öneri Sisteminin Etkilerinin Belirlenmesi" başlıklı Doktora Tezi ve TÜBİTAK 1001 Projesinde veri toplamak üzere Açıköğretim Sistemindeki öğrencilere WEB ortamında <https://drive.google.com/open?id=1OECpuFJ6WJCD2T4NqGCLbLrsUqOgHEceceYUIPr8PoA> bağlantısı üzerinden anket yapmak istiyorum. Anket sonuçlandığında verilerini ve çalışma tamamlandığında çalışmanın bir kopyasını Açıköğretim Fakültesi İstatistik Bilgi Edinme ve Değerlendirme Birimine vereceğimi taahhüt ederim.

Gereğini saygılarımla arz ederim.