

UÇUŞA ELVERİŞLİLİĞİN METEOROLOJİK
AÇIDAN İNCELENMESİ VE KISA VADELİ
KESTİRİM MODELİ İÇİN ZAMAN SERİLERİNDE
YAPAY SİNİR AĞLARI YAKLAŞIMI:
HASAN POLATKAN HAVAALANI ÖRNEĞİ

Yüksek Lisans Tezi

Ali TATLI

Eskişehir, 2016

UÇUŞA ELVERİŞLİLİĞİN METEOROLOJİK AÇIDAN
İNCELENMESİ VE KISA VADELİ KESTİRİM MODELİ İÇİN
ZAMAN SERİLERİNDE YAPAY SİNİR AĞLARI YAKLAŞIMI:
HASAN POLATKAN HAVAALANI ÖRNEĞİ

Ali TATLI

YÜKSEK LİSANS TEZİ

Havacılık Elektrik ve Elektronik Anabilim Dalı
Danışman: Yrd. Doç. Dr. Sinem KAHVECİOĞLU

Eskişehir
Anadolu Üniversitesi
Fen Bilimleri Enstitüsü
Aralık, 2016

JÜRİ VE ENSTİTÜ ONAYI

Ali TATLI'nın "Uçuşa Elverişliliğin Meteorolojik Açıdan İncelenmesi ve Kısa Vadeli Kestirim Modeli İçin Zaman Serilerinde Yapay Sinir Ağları Yaklaşımı: Hasan Polatkan Havaalanı Örneği" başlıklı tezi 29/12/2016 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Anadolu Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, **Havacılık Elektrik ve Elektronik** Anabilim dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Ünvanı-Adı Soyadı

İmza

Üye (Tez Danışmanı) : Yrd. Doç. Dr. Sinem KAHVECİOĞLU

Üye : Yrd. Doç. Dr. Yasemin IŞIK

Üye : Yrd. Doç. Dr. Haşim KAFALI

.....

Enstitü Müdürü

ÖZET

UÇUŞA ELVERİŞLİLİĞİN METEOROLOJİK AÇIDAN İNCELENMESİ VE
KISA VADELİ KESTİRİM MODELİ İÇİN ZAMAN SERİLERİNDE YAPAY
SİNİR AĞLARI YAKLAŞIMI:HASAN POLATKAN HAVAALANI ÖRNEĞİ

Ali TATLI

Havacılık Elektrik ve Elektronik Anabilim Dalı
Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Aralık, 2016

Danışman: Yrd. Doç. Dr. Sinem KAHVECİOĞLU

Bu çalışmada, havacılık otoriteleri tarafından kabul edilen standartlar ve pilot tecrübelerinden faydalanılarak aday pilotlar için meteorolojik açıdan uçuşa elverişlilik ölçütleri saptanmış, altı yılı kapsayan meteoroloji verileri de kullanılarak istatistikî sonuçlar ortaya konmuş ve günlük uçuşa elverişli saatleri içeren zaman serileri elde edilmiştir. Çalışma, günlük toplam uçuşa elverişli saat verisini içeren zaman serilerinde, yapay sinir ağları yöntemlerinden yararlanılarak izleyen günün uçuşa elverişli saat miktarı için kestirim yapılması suretiyle genişletilmiştir. Bu maksatla 10 veri seti hazırlanarak farklı aktivasyon fonksiyonları, farklı sayıda gizli katman hücreleri ve farklı geri besleme yapılarına sahip 1,824 ağ modelinde toplam 18,240 eğitim gerçekleştirilmiş ve kestirim performansları değerlendirilmiştir.

Anahtar Sözcükler: Yapay Sinir Ağları, Uçuşa Elverişlilik, Kısa Vadeli Tahmin, Enerji Fonksiyonu, Performans Ölçümleri.

ABSTRACT

INVESTIGATION OF AIRWORTHINESS IN TERMS OF METEOROLOGY AND ARTIFICIAL NEURAL NETWORKS APPROACH IN TIME SERIES FOR SHORT-TERM FORECASTING MODEL: CASE OF HASAN POLATKAN AIRPORT

Ali TATLI

Avionics Program

Anadolu University, Graduate School of Sciences, December, 2016

Supervisor: Assist. Prof. Dr. Sinem KAHVECİOĞLU

In this study, meteorological airworthiness criteria were determined using the standards accepted by aviation authorities and pilot experiences, statistical results were presented using meteorological data covering six years and time series containing daily flight time were obtained. The study is broadened in time series which contain daily total convenient time for flight via estimating for the following days convenient time for flight by make use of artificial neural network methods. For this purpose 10 data sets were setup, 18,240 trainings were performed in 1,824 network models which have various activation functions, various number of hidden layer neurons and various feedback structures and estimation performances were evaluated.

Keywords: Artificial Neural Networks, Airworthiness, Short-term Forecasting, Energy Function, Performance Measures.

ÖNSÖZ

Kıymetli hocam ve tez danışmanım Yrd. Doç. Dr. Sinem KAHVECİOĞLU'na ve değerli jüri üyelerine teşekkürlerimi sunarım.

Bu çalışma boyunca, zaman zaman bilgi ve tecrübelerine başvurduğum kıymetli hocalarım, Öğretmen Pilot Erdoğan BÖCÜ, Yrd. Doç. Dr. Emin GERMEN, Öğretim Görevlisi Nilgün ÖZTAŞ YILDIRIM'a ve çalışmaya beni teşvik eden kıymetli arkadaşım Vehbi Emrah ATASOY'a sağladıkları değerli katkılarından dolayı teşekkürlerimi sunarım.

Ayrıca T.C Orman ve Su İşleri Bakanlığı Meteoroloji Genel Müdürlüğü, Eskişehir Meteoroloji 3. Bölge Müdürlüğü, Hasan Polatkan Havaalanı Meteoroloji Birimi çalışanları ve çalışma arkadaşlarıma teşekkürü borç bilirim.

Eğitim hayatım boyunca bana destek olan ve sabır gösteren aileme, en derin hissiyatımla şükranlarımı sunarım.

Ali TATLI
Eskişehir, 2016

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 edilemeyen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Anadolu Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlakî ve hukukî sonuçlara razı olduğumu bildiririm.

Ali TATLI

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ	ix
ŞEKİLLER DİZİNİ.....	x
SİMGELER DİZİNİ.....	xvi
KISALTMALAR DİZİNİ	xvii
1. GİRİŞ.....	1
1.1. Kaos ve Nedensellik	1
1.2. Hasan Polatkan Havaalanı Genel Özellikleri.....	2
1.3. Önceki Çalışmalar	4
1.4. Yapılan Çalışmanın Önemi, Amacı ve Kapsamı.....	11
2. MATERYAL VE UÇUŞA ELVERİŞLİLİK.....	14
2.1. METAR ve SPECI Verileri.....	14
2.2. Uçuşa Elverişlilik	15
2.2.1. Rüzgâr	16
2.2.2. Rüyet.....	16
2.2.3. Bulutlar	16
2.2.4. Yağış	18
2.2.5. Gündoğumu-günbatımı.....	20
2.2.6. Uçuşa elverişlilik şartları.....	20
3. İSTATİSTİKÎ SONUÇLAR	22
3.1. Görerek Uçuşa Elverişli Zaman Aralığı	22
3.2. Uçuşa Elverişlilik	22
4. YÖNTEM	24
4.1. Yapay Sinir Ağları.....	24

4.1.1.	Yapay sinir hücreleri ve MLP	25
4.1.2.	TDNN.....	30
4.1.3.	Elman ağı.....	32
4.1.4.	NARX	34
4.1.5.	Optimizasyon teknikleri.....	35
4.1.5.1.	Levenberg-Marquardt algoritması	38
4.1.6.	Geri yayılım algoritması	42
4.1.7.	Performans ölçümleri.....	43
5.	ZAMAN SERİLERİNDE ANALİZ	48
6.	TARTIŞMA VE ÖNERİLER	76
	KAYNAKÇA.....	77
	EKLER	
	ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

	<u>Sayfa</u>
Tablo 1.1. Hasan Polatkan Havaalanı genel özellikleri	4
Tablo 1.2. Li ve Liu çalışmasındaki FNM ve BPA sınıflama oranları.....	7
Tablo 1.3. Uçuş evreleri ve meteorolojik bilgiler	12
Tablo 2.1. Rasat süreleri.....	14
Tablo 2.2. “LTBY 010025Z 26003KT 9999 -SN SCT030 BKN100 M05/M08 Q1026=” METAR veri analizi için Örnek 1.....	14
Tablo 2.3. “LTBY 271050Z 29009KT 260V320 7000 SCT030 BKN090 16/09 Q1010=” METAR veri analizi için Örnek 2.....	15
Tablo 2.4. Bulut türleri	17
Tablo 2.5. Bulut kapalılık oranları	18
Tablo 2.6. Bulutlar ve yağış türleri	20
Tablo 3.1. VFR prosedürünce öngörülen uçuşa elverişli zaman aralığı (saat)	22
Tablo 3.2. 2009 - 2014 Toplam ve ortalama uçuşa elverişli gün sayısı	23
Tablo 3.3. 2009 - 2014 Ortalama uçuşa elverişli gün sayısı.....	23
Tablo 4.1. Farklı algoritmalara ilişkin özellikler	42
Tablo 5.1. En iyi sonuçları veren ağlar için MAE, MSE, RMSE, $\rho(r)$ ve R^2 değerleri.....	50
Tablo 5.2. En iyi sonuçları veren ağlar için girdi türleri	51
Tablo 5.3. En iyi sonuçları veren ağlar için gizli katman hücre sayıları	52

ŞEKİLLER DİZİNİ

		<u>Sayfa</u>
Şekil 1.1.	Hasan Polatkan Havaalanı (LTBY) krokisi	3
Şekil 1.2.	YSA modeli	5
Şekil 2.1.	Cessna 172 SP ve TB-20 Trinidad uçaklarına ait rüzgâr bileşenleri	17
Şekil 2.2.	Bulut kapalılık oranı.....	18
Şekil 2.3.	Bulut türleri	19
Şekil 2.4.	Dünya'nın yıllık hareketi ve sonuçları	21
Şekil 2.5.	Enlemlere göre gündüz süreleri	21
Şekil 4.1.	Yapay nöron hücresi.....	25
Şekil 4.2.	Sınıflama bölgeleri	26
Şekil 4.3.	Aktivasyon fonksiyonları	27
Şekil 4.4.	MLP ağları genel yapısı	28
Şekil 4.5.	Çok katmanlı yapılar	28
Şekil 4.6.	TDNN hücre yapısı	30
Şekil 4.7.	TDNN ağları genel yapısı	31
Şekil 4.8.	TDNN ağ yapısı	32
Şekil 4.9.	Elman ağları genel yapısı	33
Şekil 4.10.	Elman ağları	33
Şekil 4.11.	NARX ağları genel yapısı	34
Şekil 4.12.	NARX ağları	35

Şekil 4.13.	Ağın ileri beslenmesi	42
Şekil 4.14.	Çıkış hücreleri için hata hesaplamaları	43
Şekil 4.15.	Gizli katman hücreleri için hata hesaplamaları	43
Şekil 4.16.	Çıkış hücreleri için ağ güncellemeleri	43
Şekil 4.17.	Gizli katman hücreleri için ağ güncellemeleri	44
Şekil 5.1.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	53
Şekil 5.2.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	53
Şekil 5.3.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	54
Şekil 5.4.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	54
Şekil 5.5.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	55
Şekil 5.6.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	55
Şekil 5.7.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	56
Şekil 5.8.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	56
Şekil 5.9.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	57
Şekil 5.10.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	57
Şekil 5.11.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	58

Şekil 5.12.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	58
Şekil 5.13.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	59
Şekil 5.14.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	59
Şekil 5.15.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	60
Şekil 5.16.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	60
Şekil 5.17.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	61
Şekil 5.18.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	61
Şekil 5.19.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	62
Şekil 5.20.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	62
Şekil 5.21.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	63
Şekil 5.22.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	63
Şekil 5.23.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	64
Şekil 5.24.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	64

Şekil 5.25.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	65
Şekil 5.26.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	65
Şekil 5.27.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	66
Şekil 5.28.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	66
Şekil 5.29.	Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	67
Şekil 5.30.	Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	67
Şekil 5.31.	Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri ..	68
Şekil 5.32.	Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri	68
Şekil 5.33.	t-1..3;ay veri setinin, 4 gizli hücreli ve elliot aktivasyon fonksiyonlu MLP ağlarında kestirim sonuçları	69
Şekil 5.34.	t-1;t-2 veri setinin, 15 gizli hücreli ve sigmoid aktivasyon fonksiyonlu MLP ağlarında kestirim sonuçları	69
Şekil 5.35.	t-1;t-2 veri setinin, 41 gizli hücreli ve lineer aktivasyon fonksiyonlu bir gecikmeli TDNN ağlarında kestirim sonuçları	69
Şekil 5.36.	t-1 veri setinin, 5 gizli hücreli ve lineer aktivasyon fonksiyonlu bir gecikmeli TDNN ağlarında kestirim sonuçları	70
Şekil 5.37.	t-1 veri setinin, 49 gizli hücreli ve lineer aktivasyon fonksiyonlu bir gecikmeli TDNN ağlarında kestirim sonuçları	70
Şekil 5.38.	t-1..5 veri setinin, 50 gizli hücreli ve elliot aktivasyon fonksiyonlu iki gecikmeli TDNN ağlarında kestirim sonuçları	70

Şekil 5.39.	t-1..4 veri setinin, 45 gizli hücreli ve sigmoid aktivasyon fonksiyonlu iki gecikmeli TDNN ağlarında kestirim sonuçları	71
Şekil 5.40.	t-1..4 veri setinin, 41 gizli hücreli ve hiperbolik tanjant aktivasyon fonksiyonlu iki gecikmeli TDNN ağlarında kestirim sonuçları	71
Şekil 5.41.	t-1..5;ay veri setinin, 26 gizli hücreli ve elliot aktivasyon fonksiyonlu üç gecikmeli TDNN ağlarında kestirim sonuçları	71
Şekil 5.42.	t-1;t-2 veri setinin, 22 gizli hücreli ve sigmoid aktivasyon fonksiyonlu üç gecikmeli TDNN ağlarında kestirim sonuçları	72
Şekil 5.43.	t-1 veri setinin, 10 gizli hücreli ve elliot aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları	72
Şekil 5.44.	t-1..3 veri setinin, 8 gizli hücreli ve sigmoid aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları ..	72
Şekil 5.45.	t-1;t-2 veri setinin, 6 gizli hücreli ve sigmoid aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları.	73
Şekil 5.46.	t-1;t-2 veri setinin, 16 gizli hücreli ve hiperbolik tanjant aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları	73
Şekil 5.47.	t-1;t-2;ay veri setinin, 21 gizli hücreli ve lineer aktivasyon fonksiyonlu bir geribeslemeli NARX ağlarında kestirim sonuçları ..	73
Şekil 5.48.	t-1;ay veri setinin, 8 gizli hücreli ve lineer aktivasyon fonksiyonlu bir geribeslemeli NARX ağlarında kestirim sonuçları	74
Şekil 5.49.	t-1 veri setinin, 26 gizli hücreli ve lineer aktivasyon fonksiyonlu bir geribeslemeli NARX ağlarında kestirim sonuçları	74
Şekil 5.50.	t-1..4 veri setinin, 37 gizli hücreli ve sigmoid aktivasyon fonksiyonlu iki geribeslemeli NARX ağlarında kestirim sonuçları ...	74
Şekil 5.51.	t-1;t-2 veri setinin, 4 gizli hücreli ve lineer aktivasyon fonksiyonlu iki geribeslemeli NARX ağlarında kestirim sonuçları.....	75
Şekil 5.52.	t-1;t-2 veri setinin, 56 gizli hücreli ve elliot aktivasyon fonksiyonlu üç geribeslemeli NARX ağlarında kestirim sonuçları	75

Şekil 5.53.	t-1 veri setinin, 30 gizli hücreli ve lineer aktivasyon fonksiyonlu üç geribeslemeli NARX ağlarında kestirim sonuçları.....	75
--------------------	--	----

SİMGELER DİZİNİ

$\Re$	: Reel sayılar
$\Re^{n \times m}$	: Reel $n \times m$ matris
δ_{MAPE}	: Ortalama Bağlı Hata, Average Relative Error
δ_i	: Maksimum Bağlı Hata, Maximum Relative Error
ρ	: Korelasyon Katsayısı, Coefficient of Correlation
R^2	: Belirlilik Katsayısı, Coefficient of Determination
$\mathcal{E}$	: Enerji fonksiyonu
$\mathbf{J}$	: Jacobian matris
$\mathbf{H}$	: Hessian matris
$\mathbf{I}$	: Birim matris
∇	: Gradyan operatörü
∇^2	: Laplasyan operatörü
$\mathbf{w}$	: Ağırlık vektörü

KISALTMALAR DİZİNİ

ABFNN	: Adaptive Basis Function Neural Network
ADALINE	: Adaptive Linear Neuron, Adaptive Linear Element
AIS	: Artificial Immune System
ANN	: Artificial Neural Networks
ANNSCGA	: ANN using Scaled Conjugate Gradient Algorithm
ARIMA	: Auto Regressive Integrated Moving Average
ARMA	: Auto Regressive Moving Average
BIAS	: Mean Error
BIC	: Bayesian Information Criterion
BPA	: Back Propagation Algorithm
CBP	: Cascaded Back Propagation
DLS	: Damped Least-Squares
EFuNN	: Evolving Fuzzy Neural Network
FNM	: Fuzzy Neuro Model
GEM	: Global Enviromental Multiscale Model
GNA	: Gauss-Newton Algorithm
GRNN	: General Regression Neural Network
ICOMP	: Information Complexity

IDNN	: Input Delay Neural Network
LMA	: Levenberg-Marquardt Algorithm
LRN	: Layer Recurrent Network
LTBY	: Hasan Polatkan Havaalanı
MAE	: Mean Absolute Error
MARS	: Multivariate Adaptive Regression Splines
ME	: Mean Error
METAR	: Meydan Rutin Hava Raporu
MLFN	: Multilayer Feedforward Network
MLP	: Multilayer Perceptron
MLR	: Multiple Linear Regression
MM5	: Fifth Generation Penn State/NCAR Mesoscale
MRE	: Mean Relative Error
NARMA	: Nonlinear Auto Regressive Moving Average
NBN	: Neuron-by-Neuron Algorithm
NGM	: Neuro Genetic Model
NMSE	: Normalised Mean Squared Error
NOKH	: Normalize Edilmiş Ortalama Karesel Hata

NWP	: Numerical Weather Prediction
OH	: Ortalama Hata
OKH	: Ortalama Karesel Hata
OMH	: Ortalama Mutlak Hata
PRNN	: Partial Recurrent Neural Network
RBFNN	: Radial Basis Function Neural Network
RMSE	: Root Mean Square Error
ROC	: Receiver Operating Characteristic
SARIMA	: Seasonal Auto Regressive Integrated Moving Average
SHT	: Sayısal Hava Tahmini
SPECI	: Havacılık Seçilmiş Özel Hava Raporu
SRN	: Simple Recurrent Network
TDNN	: Time Delay Neural Network
UTC	: Eş Güdümlü Evrensel Zaman
VFR	: Görerek Uçuş Kuralları
WRF	: Weather Research and Forecasting
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Havacılık faaliyetleri, büyük çoğunlukla atmosferin troposfer ve stratosfer katmanlarında gerçekleştirilmektedir. Meteorolojik olaylar ise atmosferin troposfer katmanında görülür ve havacılık faaliyetlerini doğrudan etkiler. Farklı kullanım amaçlarına göre tasarlanan hava araçlarının, uçuş performansları da tasarım özelliklerine göre farklılıklar göstermektedir. Kıtalar arası rotaya sahip bir uçağın, bölgesel olarak kullanılması amaçlanan bir uçağa nazaran daha dayanıklı ve daha donanımlı olması kaçınılmazdır. Uçuş eğitim organizasyonları ise gerek bakım gerek donanım maliyetleri açısından daha basit yapılı uçakları envanterlerinde bulundurmaya tercih ederler. Yine, pilot yetiştirmeyi amaçlayan bu kurumların, tecrübesiz adaylar için hava durumlarını göz önünde bulundurmaları kazaların önüne geçilebilmesi açısından büyük bir önem arz etmektedir. Tecrübesiz pilot adayları ve daha az donanıma sahip basit yapılı hava araçları meteorolojik parametrelerin iyi bir şekilde analiz edilmesini ve öngörülmesini gerekli kılmaktadır. Sonuç olarak, eğitim planlamasının önemli bir bölümünü, meteorolojik olaylar kapsamaktadır.

Havacılık, her yönüyle güvenlik ve emniyet tedbirlerinin ön planda bulunduğu bir alandır. Bu bileşenlerden biri de uçuş emniyetidir. Uçuş emniyetinin bir gereği olarak bakım çalışmaları ilgili birimler tarafından titizlikle yerine getirilmek zorundadır. Periyodik bakımlar da dâhil olmak üzere, havacılık otoritelerince yerine getirilmesi beklenen bakımlar, birimlerin önemli bir zaman bölümünü işgal etmektedir. Sektörün bu nevî kayıpları asgarî bir seviyeye indirmesi elzemdir. Uçuş yapılamayan günlerin bakım faaliyetleri için ayrılması ile süre daha verimli kullanılacaktır. Bu durum uçuşa elverişliliğin doğru analiz edilebilmesinin, planlamanın önemli bir parçası olması yönüyle, havacılık için ne denli önemli olduğunu bir kez daha ortaya koymaktadır.

1.1. Kaos ve Nedensellik

Determinizm, fiziksel bir sistemin mevcut durumunun, önceki durumunun sonucu olduğu ve çok küçük etkilerin ihmal edilebileceğini kabul eder. Buna göre keyfi küçüklükteki etkiler, sonuçta keyfi büyüklüklerde farklılıklara neden olmaz [1]. Mevcut çalışmaların ekseriyeti bu sebep-sonuç ilişkisinden hareketle gerçekleştirilmiştir. Sistemin başlangıç koşulları biliniyorsa ve analitik veya algoritmik olarak ifade edilebiliyorsa çözüme yaklaşık olarak ulaşılabilir. Başlangıç koşullarını ölçmedeki hata, her zaman çözüme yansımaktadır. 1898 yılında Fransız matematikçi Jacques Hadamard ve 1906 yılında Pierre Duhem başlangıç koşulundaki hata neticesinde sistemin uzun dönemde öngörülelemeyeceğini belirtmiştir. Henri Poincaré de 1900 yılında Güneş Sisteminin kararlı bir sistem olup olmadığının belirlenemeyeceğini

göstermiştir [2]. Özellikle geribeslemeli sistemler göz önüne alındığında başlangıç koşullarının ve amaç fonksiyonunun sistemi tanımlamadaki hassasiyetinin, çözümü nedeni etkilediği daha net ortaya çıkmaktadır. Fiziksel hiç bir nicelik tam kesin olarak ölçülemez. Ölçüm, sistematik ölçüm hatası ve rastgele ölçüm hatalarını barındırır [3]. Tam bir ölçüm mümkün olsaydı bile sonsuz basamaklı sayılara ihtiyaç duyulur ve işlem yapılamazdı. Ölçümler yapılırken belirli bir basamak sayısı kabul edilir ve dolayısıyla belirli bir hata toleransı peşinen kabul edilmiş olur. Sistemin türüne göre hatalar kabul edilebilir küçüklükte olmalı ve çözüme yaklaşıklık yeterli düzeylerde sağlanabilmelidir. Aksi halde mantıklı sonuçlar elde edilemeyecektir. Henri Poincaré'den sonra, ünlü matematikçi ve meteorolog Edward Lorenz 1963'de meteorolojik olguların başlangıç koşullarına hassas bağlı olduğunu gözlemlemiştir. Böylelikle, uzun süreli hava tahminleri yapmanın imkânsız olduğu ispatlanmıştır [1, 2, 4, 5].

1.2. Hasan Polatkan Havaalanı Genel Özellikleri

LTBY tanıtım kodu ile isimlendirilmekte olan Hasan Polatkan Havaalanı, Anadolu Üniversitesi tarafından eğitim maksadıyla kullanılmaktadır. Havaalanı 09 - 27 istikâmetinde tek piste sahiptir. Pist yüzeyi asfalt kaplama olup, her pist gibi hava durumlarından etkilenmektedir ve yetkililer tarafından uçuş planları çerçevesinde kullanıma hazır tutulmalıdır. Kar, buz, kum vs. gibi yüzeyi uçuş faaliyetleri açısından doğrudan etkileyen etmenlerin bertarafı maliyet gerektirmekte ve doğru bir planlama ışığında yapılmalıdır. Bu tez çalışması, pist planlamasını ele almamış olmasına rağmen ileriki çalışmalar için yol gösterici nitelik taşımaktadır. Meydan deniz seviyesinden 2,580 ft yükseklikte inşa edilmiştir. Konum, yükseklik gibi özelliklerin yanı sıra coğrafi ve iklimsel özellikler her havaalanı için farklılık oluşturmakta ve bu çalışma için tekrarlanabilir bir niteliğe sahip olmasına imkân vermektedir. Hasan Polatkan Havaalanı iki hangara ve bir aprona sahiptir. Yine bu çalışma, hangar ve apronun verimli kullanılabilmesi için yapılabilecek ileriki çalışmalara yol göstermeyi amaç edinmiştir. Hasan Polatkan Havaalanı'nın krokisi Şekil 1.1'de ve genel özellikleri Tablo 1.1'de verilmiştir.

AERODROME
CHART
ICAO 39°48'45"N
030°31'14"E


ELEV: 2599 FT

TWR : 123.750
GND : 121.900ESKİŞEHİR/
HASAN POLATKAN


CHANGE: WEST APRON

DHMI - ANKARA

AIRAC AMDT 03/16



SCALE : 1 / 20.000

**AERODROME LIGHTING****RWY LIGHTING**

RWY 09/27 : Edge, End, THR

OTHER LIGHTING

ABN : Flg.W,G
 TWY : Edge
 APRON : LGTD
 WDI/LDI : LGTD
 Signs : LGTD

RWY	Direction	THR	Bearing Strength
09	092.77°	39°48'37.70"N 030°30'03.45"E	PCN 110 R / D / W / T
27	272.79°	39°48'32.98"N 030°32'09.42"E	LCN 110

Şekil 1.1. Hasan Polatkan Havaalanı (LTBY) krokisi

Kaynak: [6]

Tablo 1.1. Hasan Polatkan Havaalanı genel özellikleri

IATA Tanıtım Kodu	:AOE
ICAO Tanıtım Kodu	:LTBY
Meydan Yüksekliği	:2,580 ft
Pist İstikâmeti	:09 / 27
Pist Uzunluğu	:3,000 m
Pist Genişliği	:45 m
Pist Kaplaması	:Asfalt
Şehir merkezinden uzaklık	:2.7 NM N
Koordinatları	:AD 39°48'45"N - 030°31'14"E

Kaynak: [6, 7]

1.3. Önceki Çalışmalar

Çalışma kapsamında yapılan araştırma sonucu, literatürde meteorolojik açıdan uçuşa elverişliliğin tahminine yönelik herhangi bir çalışmaya rastlanmamıştır. Elverişlilik konusu daha çok pilot ve hava aracı açısından elverişliliğin incelenmesi suretiyle yapılan tıbbî ve teknik araştırmalar şeklindedir [8–10]. Geçmiş verilerden, gelecek verilerin tahmininden başka olarak, veri setlerindeki eksik verileri tahmin etmeyi amaçlayan, interpolasyon¹ tabanlı çalışmalar mevcuttur. Bu çalışmaya benzer olarak nitelendirilebilecek çalışmalar ise çoğunlukla sıcaklık, yağış, rüzgar hızı, rüzgar gücü, sis ve su debisi üzerine yoğunlaşmıştır. Yine uçakların türü ve yaşını göz önünde bulundurarak arıza yapacağı zamanı tahmin etmeyi amaçlayan çalışmalar vardır. Bu çalışmaya en yakın çalışma olarak meteorolojik bazı veriler ve hava trafik kontrol verileri ile uçuş süresi tahminine yönelik bir çalışma bulunmaktadır [13].

Benzer çalışmalarda genel olarak ortalama değerler kullanılarak tahminlerde bulunulmaya çalışılmıştır. Meteorolojik verilerin kaotik yapısı, tıpkı finans verileri gibi yüksek frekans bileşenlerine sahiptir ve tahmin edilmesi güç problemlerden biridir. Bu sebeple araştırmacılar, çalışmalarda genellikle ortalama değerler kullanarak uzun periyotlar boyunca gerçekleşen değişimleri incelemeye yoğunlaşmıştır. Böylelikle değişkenlerin değişim hızı düşmüş ve ortalamaların alınmasıyla yüksek frekans bileşenleri filtrelenmiştir. Hu ve Root 1964 yılında k-adaline modelini kullanarak, “yağış var” ve “yağış yok” şeklinde çıktılar üreten öncü çalışmalardan birini gerçekleştirmişlerdir. 1956 ile 1963 yılları arasını kapsayan çalışmaları resmî tahminlerle ağ tahminlerinin doğruluğunu kıyaslamakta ve buna göre yarın ve akşam tahminlerinde modelin yağışın fiziksel oluşum bilgisinden yoksun olmasına rağmen iyi sonuçlar elde ettiğini ortaya koymaktadırlar [14].


Luk, Ball ve Sharma çalışmalarında Yukarı Parramatta Nehri Havzası’nda ya-

¹Büyük veri kümeleriyle yapılan çalışmalarda eksik verilerin olması kaçınılmaz bir durum olarak nitelendirilebilir. Lineer, logaritmik, kübik, polinomial v.s. gibi istatistikî interpolasyon yöntemleri olduğu gibi yapay zeka teknikleri de eksik verileri tamamlama maksadıyla kullanılabilir. Bkz. [11, 12]

ğış miktarı tahmini yapmak için MLFN (Multilayer Feedforward Network), PRNN (Partial Recurrent Neural Network) ve TDNN (Time Delay Neural Network) yapılarını kestirimci olarak, NMSE(Normalised Mean Squared Error)'yı bir karşılaştırma kriteri olarak kullanmışlar ve sonuç olarak bu ağ yapılarını kıyaslamışlardır. Elde ettikleri sonuca göre belirli konfigürasyonlarda ağ yapıları yaklaşık kestirimlerde bulunmuştur. TDNN yapılarında, gecikme süresinin artmasıyla NMSE'nin arttığı sonucuna ulaşmışlardır [15].

São Paulo bölgesi yağış kestirimi için yapılan bir çalışmada YSA (Yapay Sinir Ağları), MLR (Multiple Linear Regression) ve meteoroloji istasyonundan elde edilen Lewis Fry Ricardson'ın öncülük ettiği denklem tabanlı bir tahmin modeli olan NWP (Numerical Weather Prediciton) ile gözlenen gerçek değerler arasında bir karşılaştırma yapılmıştır. Bu karşılaştırma sonucunda da YSA yönteminin MLR ve NWP'a göre daha başarılı olduğu ortaya konulmuş ve YSA giriş verilerinin azaltılması için dalgacık dönüşümü önerilmiştir. Bu çalışmada karşılaştırma kriteri olarak BIAS (Mean Error), MAE (Mean Absolute Error), RMSE (Root Mean Square Error) ve ρ (Correlation Coefficient) kullanılmıştır [16].

Charaniya ve Dudul tarafından elli yıllık (1955 - 2005) aylık yağış ortalamaları üzerinden kestirim modeli oluşturulmuştur. Bu modele göre dalgacık dönüşümü ile veriler yüksek frekans bileşenlerinden ayrılmış ve iki ayrı YSA modeli kullanılarak tahmin yapılmıştır. Kullandıkları model Şekil 1.2'de verilmiştir [17].



Şekil 1.2. YSA modeli

Kaynak: [17]

Rani ve Govardhan, 1871 - 2005 yılları arasındaki aylık verileri kullanarak YSA'yı eğitmiş ve 2006 - 2011 yılları arasındaki verileri test için kullanmışlardır. Andhra Pradesh'de Box-Jenkins metodolojisini² kullanarak SARIMA modeli kurmuş ve MLFN modeli ile kıyaslayarak, YSA'nın kabul edilebilir tahminler yaptığı sonucuna ulaşmışlardır [19].

Öztopal ve Şen, bulut tepe sıcaklığı ile kısa vadeli yağış tahminini YSA yöntemleriyle gerçekleştirerek, bulut tepe sıcaklığının, troposferin düşey seviye verileriyle kıyaslandığında daha yüksek oranda korelasyona sahip olduğu sonucuna ulaşmışlardır. Çalışma, performans kriteri olarak ROC (Receiver Operating Characteristic) olarak bilinen POD (Probability of Detection), BIAS, FAR (False Alarm Ratio), CSI(Critical success index), HR (Hit Rate)'i kapsamaktadır [20, 21].

Abhishek ve ark. yağış tahmini için BPA (Back Propagation Algorithm), LRN (Layer Recurrent Network) ve CBP (Cascaded Back Propagation) ağları arasında farklı öğrenme fonksiyonları ve farklı sayıda sinir hücreleri kullanarak modeller oluşturmuş ve modelleri kıyaslamışlardır. Bu çalışmaya göre matematiksel veya istatistiksel metodların hesaplamalarda çok sağlıklı veriler ortaya koyabilmesine rağmen, kestirim söz konusu olduğunda gerçek hayatta düzensiz bir şekilde değişen verilerin öğrenme kabiliyetine sahip YSA ile daha doğru sonuçlara ulaştığı yorumu yapılmıştır [22].

Minimum ve maksimum sıcaklık, su buhar basıncı ve buharlaşma girdilerini kullanarak BPA, LRN ve TDNN algoritmalarını yağış tahmininde kıyaslayan Dubey, TDNN algoritmasının farklı eğitim fonksiyonlarında da BPA ve LRN'ye nazaran daha düşük MSE değerlerine sahip olduğu sonucuna ulaşmıştır [23].

Li ve Liu, Kaba Küme Teorisi³ tabanlı FNM kullanarak gerçekleştirdikleri çalışmalarında tic-tac-toe oyun sonu, kalp hastalıkları, iş görüşmeleri, hipotiroid ve karaciğer ile ilgili yaptıkları sınıflama problemlerinin çözümünde kaba küme tabanlı bulanık sinir ağlarının, BPA'ya göre daha başarılı olduğu sonucuna ulaşmışlardır. Elde ettikleri sonuçlar Tablo 1.2'de gösterilmektedir. Bu sonuçlar çerçevesinde giriş verisi çiğ sıcaklığı, rüzgar hızı, sıcaklık ve bu verilere ek olarak havanın karlı, yağmurlu, sisli veya açık olduğuna dair bir hava durumu bilgisi olmak üzere rüyet tahmini yapmaya çalıştıkları 4 giriş ve 1 çıkışlı bir model ortaya koymuşlardır. Çalışmaları, kestirimden daha çok bir sınıflama problemi çalışmasıdır [26].

Abraham ve ark. yağış tahmini için EFuNN (Evolving Fuzzy Neural Network),

²Box-Jenkins, tek değişkenli zaman serilerinin ileriye yönelik tahminlerinde kullanılan istatistiksel bir kestirim yöntemidir. Zaman serilerinin belirli örneklerle durağan (stationary) yani ortalamasının ve varyansının değişmediği varsayılır. Böylece zaman serisi dönüşüm yapılarak uygun bir model şeklinde durağanlaştırılır. Durağanlık testini geçen model tahmin için kullanılabilir [18].

³1982 yılında Zdzislaw Pawlak tarafından ortaya atılan veri özelliklerinin farklılık ve benzerliklerini ortaya koyabilen, özellik indirgemesi yapabilen, belirsizliklerin giderilmesi için kullanılan veri madenciliğinde sıklıkla uygulama alanı bulmuş bir yöntemdir [24, 25].

Tablo 1.2. Li ve Liu çalışmasındaki FNM ve BPA sınıflama oranları

Veri Kümesi	FNM	BPA
Tic-Tac-Toe oyun sonu	%95.7	%95.1
Kalp hastalıkları	%94.6	%92.3
İş görüşmeleri	%90.4	%88.1
Hipotiroid	%97.3	%96.8
Karaciğerle alâkalı sınıflama	%94.1	%92.7

Kaynak: [26]

ANNSCGA (Artificial Neural Network using Scaled Conjugate Gradient Algorithm), ABFNN (Adaptive Basis Function Neural Network), GRNN (General Regression Neural Network) ve MARS (Multivariate Adaptive Regression Splines) modelleri arasında karşılaştırma yapmışlardır. Bu amaçla 87 yıl boyunca aylık verilerin 40 yılını eğitim ve 47 yılını da performans testi için kullanmışlardır. Çalışmada en iyi sonuçların, tahminlerin 1 hafta zaman dilimi içerisinde gerçekleştirildiğinde elde edilebileceğine vurgu yapılmıştır. Sonuç olarak YSA yöntemlerinin eğitim aşamasında daha düşük RMSE hatasına sahip olmasına rağmen, test aşamasında MARS yöntemi daha iyi sonuç vermiştir. Fakat yine de test aşamasındaki bu hata değerleri birbirine çok yakındır [27].

Farklı bir çalışma olarak, Saplıoğlu ve Çimen üç meteoroloji istasyonunun günlük yağış verilerini kullanarak bir diğer istasyondaki durumu tespit etmeyi amaçlamışlardır. Böylelikle, yeni kurulan, ölçüm yapılamayan istasyonlar veya kayıtlardaki eksik eski verilerin interpolasyonu için kullanılan ağırlıklı ortalama ve harmonik ortalama metodlarına bir alternatif sunmayı başarmışlar ve YSA'nın iyi bir alternatif olduğu sonucuna varmışlardır [28].

Shoba ve Shobha, farklı veri madenciliği yöntemlerini kullanan çalışmaları tetkik etmişler ve machine learning (makine öğrenmesi) tabanlı tekniklerin kestirim amaçlı olarak geleneksel yöntemlere iyi bir alternatif olduğu sonucuna ulaşmışlardır [29].

Zhang ve ark. yağış tahmini için ilginç bir çalışma yapmışlardır. Bu çalışmada farklı YSA metodlarını aynı amaca yönelik olarak eş zamanlı kullanan YSA grubu kullanmış ve YSA sonuçlarını derleyerek ortak bir sonuç elde etmişlerdir. Buna göre toplam yağış olaylarındaki yağış kestiriminin ortalama hatası, %10'ların altına düşürülebilmekte ve geleneksel metodlara göre 10 kat daha hızlı kestirim yapılabilir. Bu çalışma ile hibrid sistemlerin başarısı ortaya konulmuştur [30].

Shafie ve ark. dinamik ve statik YSA yöntemlerini Klang Nehri Havzası'nda yağış tahmini yaparak karşılaştırmışlar ve TDNN⁴ modelinin haftalık ve aylık tahminlerde kayda değer bir başarı elde ettiği sonucuna ulaşmışlardır. Haftalık verilerden oluşan kestirim için 1997 - 2008 yıllarını kapsayan 12 yıllık ve aylık verilerden

⁴Literatürde IDNN(Input Delay Neural Network) şeklinde de geçmektedir.

oluşan kestirim için 1987 - 2008 yıllarını kapsayan 22 yıllık bir veri kümesi kullanmışlardır [31].

Partal ve ark. dalgacık dönüşümü ile farklı istasyonlardan aldıkları verileri detay bileşenlerine ayırarak, geçmiş verilerin detay bileşenleriyle korelasyon ilişkisini inceleyen bir çalışma yapmışlardır. Yeterli korelasyon sağlayan bileşenler elde edildikten sonra BPA ve RBFNN (Radial Basis Function Neural Network) ile tahminler yapılmış ve BPA'nın daha iyi performans gösterdiği sonucuna ulaşmışlardır [32, 33].

Hayati ve Mohebi yaptıkları çalışmada 10 yıllık ıslak termometre sıcaklığı, kuru termometre sıcaklığı, rüzgar hızı, nem, basınç, güneş ışığı ve radyasyon bilgilerini kullanarak kuru sıcaklık değerlerini MLFN⁵ modeli ile tahmin etmeye çalışmışlardır. Yaz, kış, ilkbahar ve sonbahar dönemleri için ayrı ayrı YSA modelleri kurarak nöron ağırlıklarının mevsimlere göre özelleşmesini amaçlamışlar ve sonuç olarak tahminlerde yaz aylarında MAE'nin diğer mevsimlere göre daha düşük olduğu ve diğer mevsimlerin ise yaklaşık MAE değerlerine sahip olduğu sonucunu elde etmişlerdir. Yaz mevsimi için 6, diğer mevsimler için 4 gizli katman nöronu kullanılan bu çalışmada, eğitim iterasyonları eşit ve 2000'dir. Gizli katmanda tan-sig ve çıkış katmanında ise pure-linear fonksiyonları kullanılmıştır [34].

Dombaycı ve Gölcü, Denizli ili için gerçekleştirdikleri çalışmada günlük ortalama sıcaklığı tahmin etmeye çalışmışlar ve 3 ila 30 arasında değişen gizli katman nöronları arasından 6 nörona sahip model en yüksek belirlilik katsayısı (R^2) ve en düşük RMSE hatasına sahip olarak tespit edilmiştir [35].

Banik ve ark. tarafından gerçekleştirilen Dhaka günlük sıcaklık tahmini ile ilgili çalışmada FNM (Fuzzy Neuro Model) ve NGM (Neuro Genetic Model) ağırları, ARIMA modeli ile RMSE, ρ ve R^2 kriterlerine göre kıyaslanarak genetik modelin, fuzzy model ve Box-Jenkins modeline göre daha doğru kestirim yapabildiği sonucu ortaya konulmuştur. Çalışmada Şubat 1945 ve Ağustos 2006 yıllarını kapsayan geniş bir veri kümesi kullanmışlardır [36].

Canberra Uluslararası Havalimanı sis durum tahmini için yapılan çalışmada 44 yılı kapsayan TAF⁶ verilerini kullanmışlardır. Çalışmada NWP modeline ve personelin bazı değerler üzerinden tecrübelerine yönelik yapmış oldukları sis tahminine kıyasla, Canberra bölgesi için YSA modelinin kullanıma uygun bir yöntem olduğu sonucunu elde etmişlerdir. Bu çalışmada performans kriteri olarak ROC⁷ analizinin kullanılması çalışmayı, mevcut benzer çalışmalardan ayırmaktadır [41].

⁵Literatürde MLP(Multi Layer Perceptron) şeklinde de geçmektedir.

⁶Periyodu 6 saatten az, 30 saatten fazla olmayan (6, 9, 18, 24 veya 30 saat aralıklı) ve hava alanı ile çevresinde hüküm süren meteorolojik olayları gösteren rapordur [37, 38].

⁷ Empirik çalışmalarda; durumların tespitlerinin doğruluğu bir kriter olarak kullanılmaktadır. Bunun yanısıra durumlar hakkında ne denli doğru tespitlerin yapıldığı, ROC eğrileriyle ifade edilir. ROC analizi, doğru pozitifler ve yanlış pozitifler arasındaki ilişkinin incelemesine olanak sağlayan bir analiz türüdür [39, 40].

Brezilya Maceló havalimanında sis kestirimi üzerine Costa ve ark. tarafından yapılan çalışmada rüyet, sis derecesinin bir ifadesi olarak kullanılmış ve bu amaçla rüzgar yönü, rüzgar hızı, çiğ noktası sıcaklığı, kuru termometre sıcaklığı, yaş termometre sıcaklığı, bağıl nem verileri girdi olarak kullanılmıştır [42].

Aktaş ve Erkuş tarafından yapılan çalışma, lojistik regresyon analizi ile Eskişehir’de sis oluşumunu istatistiksel olarak incelemektedir. Çalışmada sıcaklık, nem, basınç, rüzgar hızı ve kapalılık değerleri kullanılarak sis oluşup oluşmayacağı tahmin edilmeye çalışılmıştır. Niceliklere göre sınıflama oranı %93 olarak bulunmuş ve değişkenlerin girilmesiyle sis oluşumunun gerçekleşip gerçekleşmeyeceğine yönelik olasılıkları ortaya koyacak bir denklem elde edilmiştir [43].

Colabone ve ark. tarafından yıl, ay, gün, saat, sıcaklık, bağıl nem, basınç ve rüzgar hızı değişkenleriyle São Paulo bölgesi için saatlik verilerle bir çalışma gerçekleştirilmiştir. MLP modeli ile yapılan çalışmada, verilerin 2/3’ünü eğitim 1/3’ünü ise test amacıyla kullanarak %95.949 eğitim ve %98.107 test başarısı yakalamışlardır [44].

Wen ve Wang’ın sigmoid fonksiyonunu, transfer fonksiyonu olarak kullandıkları çalışmaları hava trafik kontrol ve hava durumu verilerini kullanarak aynı tip uçaklar için birbirine yakın olması beklenen uçuş süresini tahmin etmeye çalışmıştır. Bu çalışmada pilot tecrübesi ve kabiliyetleri ihmal edilmiş ve BIC⁸ (Bayesian Information Criterion)’e göre gizli katman nöron sayısı belirlenmiştir. Çalışmalarında 60 eğitim ve 24 de test maksatlı olmak üzere 21 günü kapsayan 84 parça verinin kullanıldığı, performans değerlendirmeleri için ise δ_i ve δ_{MAPE} kullanarak çalışmalarını gerçekleştirmişlerdir [13].

Atik ve ark. yaptıkları çalışmada Zonguldak ili için gerçekleştirilen bir çalışmada 1995-2004 yılları arasındaki 10 yıllık bir veri seti kullanılmıştır. Çalışma kapsamında YSA’ya atmosfer dışı güneş ışınlam şiddeti, deklinasyon açısı ve güneşleme süresi verileri verilmiş ve çıkış olarak da atmosfer içindeki ışınlam şiddeti, rüzgâr hızı ve hava sıcaklığı bilgileriyle ilişki kurulmaya çalışılmıştır. Modelde Kalagirio ve Bojic’in önermiş olduğu (4.7) kullanılarak, gizli katman nöron sayısı yaklaşık 6 olarak hesaplanmış ve eğitimde MRE kriter alınarak $e \leq 10^{-4}$ değerine ulaşıncaya kadar eğitim sürdürülmüştür [46].

Altay ve ark. uçak tipi ve yaşına bağlı olarak arıza zamanını tespit edecek bir model geliştirmeyi ve böylelikle planlama için faydalı bir model ortaya koyabilmeyi amaçlamışlardır. 60 uçağın 2 yıl boyunca 532 arıza verisini incelemişlerdir. Eksponansiyel, logaritmik, lineer ve üstel fonksiyonların bileşeminden bir tahmin denklemini model olarak kullanmış ve parametrelerini genetik algoritma yöntemiyle

⁸Ağın ihtiyaçlarına göre nöron sayısını sistematik bir şekilde arttırarak model için en uygun sayıda nöronu tespit etmeyi amaçlayan metoddur [45].

bulmuşlardır. Ayrıca MLP modeli de genetik algoritma kullanılarak optimize edilmeye çalışılmıştır [47].

Kamil ve ark. tarafından NWP modelleri olan MM5 (Fifth Generation Penn State/NCAR Mesoscale) ve WRF (Weather Research and Forecasting), yalnızca istatistikî olarak 6, 12 ve 24 saatlik tahminlerde incelenmiştir. Çalışmada, WRF modelinin 12 ve 24 saatlik tahminlerde daha başarılı olduğunu, RMSE hatasının daha düşük olduğunu ortaya koyarak göstermeye çalışmışlardır. Çalışma sonucuna göre iki model arasındaki fark çok önemli değildir ve modeller birbirine oldukça yakındır [48].

Akbilgiç ve Kesintürk tarafından YSA ve çoklu regresyon⁹ analizinde kullanılan en küçük kareler yöntemi ve robust (gürbüz) regresyon¹⁰ yöntemleri Huber, Tukey ve Andrew M-kestiricileri ile MSE ve ICOMP (Information Complexity) kriterine göre kıyaslanmış ve YSA'nın üstünlüğünü ortaya koyarak iyi bir alternatif olduğu sonucuna ulaşmışlardır [49].

Watters ve Leahy, NWP modeli olan GEM (Global Enviromental Multiscale Model), Fourier serisi denklemini içeren temel bir lineer regresyon ifadesi, temel yapıda log-sigmoid aktivasyon fonksiyonlu 3 gizli katman hücresine sahip MLP modeli ve Kalman filtreleme yöntemleri ile gözlemlenen Ocak 2009 - Temmuz 2010 rüzgar hızı verilerini tahmin etmeye çalışmıştır. Neticede, Kalman filtreleme ve YSA modelinin tahminlerinin, gerçek veriler ile korelasyonunun sürekli arttığını ve tahmin güvenilirliğini arttırmak için kullanılabileceği sonucuna ulaşmışlardır. Bu çalışmada preformans kriteri olarak BIAS, MAE, RMSE ve ρ 'yu kullanmışlardır. Araştırmacılar Kalman filtrelemenin daha başarılı olduğunu düşünmektedirler [50].

Paras ve Mathur, Nisan 1996 ve Mart 1999 zaman dilimini kapsayan çalışmalarında MLR kullanarak maksimum sıcaklık, minimum sıcaklık ve bağıl nemin yağışla korelasyonu olduğunu ortaya koyarak herhangi bir veya birden çok parametreden sağlanan istatistikî göstergeler MA (Moving Avarage), EMA (Exponential Moving Avarage), ROC (Rate of Change), OSC (oscillator), μ_2, μ_3, μ_4 (Moments), skewness ve kurtosis katsayılarının modele giriş parametreleri olarak kullanımlarıyla diğer parametrelerle ilişkilendirilebileceği sonucuna ulaşmışlardır [51].

Weiguo basınç, basınç farkı, basınç farkı sembolü (-,+), günün rüzgar yönü şeklinde isimlendirdiği veriler ile bugün, yarın ve ertesi gün için “yağış var” ya da “yağış yok” kestirimini AIS (Artificial Immune System) ve YSA ile yapmaya çalışmıştır [52]. Çalışma, YSA modeli ile ilgili herhangi bir bilgi içermemekle birlikte AIS'in daha doğru sonuçlar elde ettiği şeklinde bir sonuca ulaşmıştır.

⁹Regresyon analizi, bir değişkenin bir veya çok sayıdaki değişkenlerle ilişkisini formülize eden yöntemdir.

¹⁰Robust regresyon, modelin sonuçlarının yanlış olması durumunda aykırı değerlerden etkilenmeyi azaltarak hatayı minimize eden yöntemlere verilen genel isimdir.

Atasoy, yapmış olduđu tez çalışmasının bir bölümünde uçuş eğitim organizasyonu açısından meteorolojinin önemini incelemiş ve uçuşa elverişli gün sayısı üzerine 2012 ve 2013 yıllarını kapsayan 17280 METAR verisi üzerinde istatistikî bir çalışma yapmış ve sıcaklığın $+25^{\circ}$ C’den yüksek olduđu günleri, karla örtülü günleri, yan rüzgârın 15 kt’dan büyük olduđu günleri, yağmurlu günleri, şiddetli don yaşanan günleri ve sisli günleri tespit ederek istatistikî bir çalışma gerçekleştirmiştir [37].

1.4. Yapılan Çalışmanın Önemi, Amacı ve Kapsamı

Meteorolojik olaylar kaotik bir süreçte meydana gelen, tahmin edilmesi zor değişkenleri içerisinde barındırır. Şöyle ki, ölçümlerin ayrık zamanlı olması ve değişkenlerin kısa sürelerde büyük değişikliklere uğrayabilmesi kestirimi zorlaştırmaktadır. Değişkenlerin başlangıç koşullarına hassas bağıllığı nedeniyle Bölüm 1.1’de bahsedildiği üzere, tahmin zamanı ölçüm anından uzaklaştıkça, kestirim güçleşmektedir. YSA, nonlinear (doğrusal olmayan) ilişkileri modellemede sahip olduđu üstün kabiliyetler neticesinde istatistikî yöntemlere nazaran daha iyi sonuçlar ortaya koyabilmektedir. Bunun temel sebebi Box-Jenkins metodolojisinde olmayan öğrenebilme yeteneğidir.

“Herhangi bir kararın etkinliği kararı izleyen durumun verilen karara uygunluğu ile belli olur. Karar vermeden önce bu kontrol edilemeyen durumların tahmin edilebilmesi verilecek kararlar üzerindeki başarı yeteneğini arttırır. Yani tahmin yapmak karardaki riski azaltmaktadır [32, 53]”.

Havacılık sektörünün, faaliyetleri sürecinde yüksek riskler taşıması ve yanlış kararların önemli sonuçlar doğurması çalışmanın önemini vurgulamaktadır. Uçuşun üç aşaması olan kalkış, iniş ve seyir evrelerinin her birinde meteoroloji istasyonlarınca yapılan yer gözlemlerine ihtiyaç vardır. Uçuş evreleri ve ihtiyaç duyulan meteorolojik bilgilere Tablo 1.3’de değinilmiştir. Uçaklar tarafından rapor edilmesi zorunlu koşulan hava olayları ise şunlardır [38, 54]:

- şiddetli türbülans
- buzlanma
- dağ dalgası
- oraj (thunderstorm)
- toz veya kum fırtınası
- volkanik olaylar
- cumulonimbus bulutları
- dolu
- rüzgâr kesmesi (wind shear)

Türbülans, hava kütleleri arasında oluşan hafif, orta ve şiddetli şeklinde ifade edilen hava hareketlerine; dağ dalgası, şiddetli rüzgârda dağ üzerlerinde oluşan ‘MTW’ koduyla raporlanan bir hava olayına; oraj, METAR rasatlarında ‘TS’ koduyla rapor edilen ve cumulonimbus bulutlarının neden olduğu şimşek ve gök gürültüsünün bir yağış eşliğinde gerçekleştiği hava olayına; rüzgâr kesmesi (wind shear) ise rüzgârın yönünde ve hızında, yatay veya düşey olarak meydana gelen ani değişikliklere verilen isimdir.

Tablo 1.3. Uçuş evreleri ve meteorolojik bilgiler

Optimum uçuş yolu için gerekli bilgiler	:NWP tahmin bilgileri Kalkış, iniş ve yedek meydan tahminleri Önemli hava kartı (SWC)
Toplam ağırlık hesabı	:Rüzgâr, sıcaklık, basınç verileri
Kalkış tahminlerinin kontrolü	:Rasat bilgileri
Kalkış evresi	:Alçak irtifâ rüzgâr shear’ı Hava yoğunluğundaki hızlı değişme Şiddetli türbülans ve buzlanma Oraj ve önemli diğer hava olayları
Tırmanma evresi	:Önemli hava olayları (Kod 4678) Uçuş sahasında beklenen rüzgar ve sıcaklık
İniş evresi	:İlgili hava alanın hâlihazırda hava şartları TREND† tahmini

† METAR raporunun sonuna eklenen ‘BECMG’ (hâlihazırda) ve ‘TEMPO’ (kısa süreli) kodlarıyla verilen özellikle iniş aşamasında kullanılan rapor.

Kaynak: [38, 55]

2000 - 2011 yılları arasında yaşanan 309 uçak kazasının 73’ü meteorolojik olaylar neticesinde gerçekleşmiş ve 2009 yılında gerçekleşen 9 meteorolojik olay 282 kişinin hayatını kaybetmesine sebep olmuştur [37]. Ticarî organizasyonlar açısından değerlendirildiğinde, hava araçlarının faaliyetlerini gerçekleştiremeyeceği sürelerin bakım faaliyetlerine ayrılması maliyetlerin asgarî bir düzeyde tutulması açısından önem taşımaktadır. Meteorolojik olaylar, tecrübesiz pilot adayları açısından ise daha büyük riskler taşımaktadır. Bu çalışmada, havacılık sektöründe risklerin ve maliyetlerin kontrol altına alınabilmesine yönelik olarak meteorolojik anlamda gerekli öngörüler YSA’nın kabiliyetleriyle kullanılarak iyileştirilmeye çalışılmıştır.

Çalışmanın birinci bölümünde hava durumlarını da içeren “ölçme” ve “tahmin etme” kavramlarına felsefî bir bakış açısıyla değinilmekle birlikte çalışma alanı ve amacına ilişkin açıklamalar yapılmakta ayrıca benzer olarak değerlendirilebilecek çalışmalara yönelik tanıtıcı bilgiler verilmektedir. İkinci bölümde çalışma kapsamındaki kestirim modellerinde kullanılacak olan veri setinin oluşturulması ve bu aşamada kullanılan ölçütler anlatılmaktadır. Üçüncü bölüm, çalışma bölgesi için uçuşa elverişli gün sayısını istatistikî anlamda değerlendirmektedir ve kestirim çalışmasından ayrı bir çalışma niteliğindedir. Anadolu Üniversitesi Pilotaj Bölümü tarafından yapı-

lan planlamalarda deęerlendirilmek üzere alıřmaya eklenmiřtir. Dördüncü bölümde kestirim yöntemleri incelenmiřtir. Beřinci bölümde yöntemlere iliřkin elde edilen sonuçlar açıklanmakta, Altıncı bölümde ise elde edilen sonuçlara yönelik yorumlar yer almaktadır.

2. MATERYAL VE UÇUŞA ELVERİŞLİLİK

ICAO, Annex 3 Chapter 8’de havacılıkla ilgili bilimsel çalışmalarda hava durumlarıyla ilgili verilerin en az beş yıllık gözlem sonucunu kapsamasını bir gereklilik olarak kabul etmiştir [54]. Dolayısı ile, bu tez çalışması, Ocak 2009 - Haziran 2015 ($\approx 6\frac{1}{2}$ yıl) zaman aralığını kapsayan 58053 adet METAR (Meydan Rutin Hava Raporu) ve SPECI (Havacılık Seçilmiş Özel Hava Raporu) verileriyle gerçekleştirilmiş olup, böylece ICAO gereklilikleri sağlanmıştır.

2.1. METAR ve SPECI Verileri

Havacılık maksatlı rasatlar, havacılık ve meteoroloji otoritelerince belirlenen bir takım kurallar neticesinde yapılır. Atomik olarak hesaplanan uluslararası bir zaman sistemi olan UTC (Eş Gündümlü Evrensel Zaman) olarak hesaplanan bu rasatlar, METAR ve SPECI olmak üzere iki şekildedir. Tablo 2.1’de havaalanı türüne göre METAR rasatları ile ilgili süreler verilmiştir. SPECI rasatlar, rutin METAR rasatlarına ek olarak önemli meteorolojik olayların gerçekleşmesi veya meteorolojik parametrelerin belirli değerleri aşması veya düşmesi halinde yapılır [38]. Düzenlenme yönüyle METAR ve SPECI raporları birbirlerinin aynısıdır ve içerdikleri bilgiler aynı formata sahiptir. Kullanılan METAR veri yapılarına ait örnekler, analiz ve yorumlama Tablo 2.2 ve Tablo 2.3’de verilmektedir.

Tablo 2.1. Rasat süreleri

Uluslararası meydanlar	:30 dk’da bir
Ulusal meydanlar	:1 saat’te bir
Askerî meydanlar	:1 saat’te bir
Gündoğumu-Günbatımı çalışan meydanlar	:uçuş saatlerini kapsayacak şekilde

Kaynak: [38, 55]

Tablo 2.2. “LTBY 010025Z 26003KT 9999 -SN SCT030 BKN100 M05/M08 Q1026=”
METAR veri analizi için Örnek 1

İstasyon adı	: LTBY
Rasat saati	: Ayın 01’nci günü 00:25 UTC
Ortalama rüzgar	: 260°’den 3 kt
Hakim rüyet	: ≥ 10 km
Halihazır hava	: Hafif kar
Bulutlar	: 3/8 - 4/8 okta 3,000 ft, 5/8 - 7/8 okta 10,000 ft
Hava sıcaklığı	: -5° C
İşba sıcaklığı	: -8° C
QNH	: 1026 hPa

Tablo 2.3. “LTBY 271050Z 29009KT 260V320 7000 SCT030 BKN090 16/09 Q1010=”
METAR veri analizi için Örnek 2

İstasyon adı	: LTBY
Rasat saati	: Ayın 27’nci günü 10:50 UTC
Ortalama rüzgar	: 290°’den 9 kt
Rüzgar yönü	: 260° ve 320° arasında değişken
Hakim rüyet	: 7 km
Bulutlar	: 3/8 - 4/8 okta 3,000 ft, 5/8 - 7/8 okta 9,000 ft
Hava sıcaklığı	: +16° C
İşba sıcaklığı	: +9° C
QNH	: 1010 hPa

2.2. Uçuşa Elverişlilik

Askerî uçaklar tasarımları gereği meteorolojik şartlara yüksek tolerans gösterirler. Ticarî yolcu uçaklarının ise yalnızca kalkış ve iniş evrelerinde meteorolojik hadiselerden etkilenmeleri söz konusudur. Seyir evresi genellikle 30,000 - 39,000 ft (9 - 12 km) irtifâlarında, stratosferin alt seviyelerinde gerçekleştirilir. Bilindiği üzere stratosfer, su buharı ve iklim olaylarının görülmediği, alt kademelerinde sıcaklık değişiminin az olduğu, yer küreye yakınlıkta ikinci atmosfer kademesidir. Böylelikle ticarî uçaklar düşük sıcaklıklarda ve düşük hava yoğunluklarında hava aracının kendi varlığından kaynaklı yüzey, profil ve enterferans sürüklenme kuvvetlerinden oluşan parazit sürüklemeyi azaltarak yakıt tasarrufu sağlarlar ve meteorolojik hadiselerden etkilenmezler.

Uçuş eğitim organizasyonları ağırlıklı olarak uçuşlarını VFR (Görerek Uçuş Kuralları) ve bu prosedüre uygun uçaklarla troposfer katmanında, uçuş prosedürlerine göre gerçekleştirmektedirler. Türk AIP’sine göre; bulut tavanı 1,500 ft’in (450 m) altına indiğinde, 5 km altında rüyet ve gece şartları¹ olduğunda VFR uçuş yapılamaz [6, 56–58]. Havacılığı etkileyen önemli meteorolojik hadiselerin gerçekleşme ihtimali göz önüne alınarak Meydan ihbarları, SIGMET mesajları, AIRMET mesajları ve GAMET mesajları yayınlanır. Kalkış ve iniş evrelerinin gerçekleştirildiği meydanlar meteorolojik olaylardan olumsuz etkilenebilmekte ve meydan yetkililerinin gereken tedbirleri alabilmeleri için meydan ihbarları yayınlanmaktadır. Pilotların ve havacılıkla ilgili diğer personelin bilgisine sunulmak üzere uçuş faaliyetleri üzerinde etkisi olan önemli hava olaylarının zaman ve yer içerisindeki oluşumunu ve gelişimini içeren, SIGMET mesajları yayınlanır. AIRMET mesajları 15,000 ft (FL150)’i geçmeyen uçuş faaliyetleri için rota üzerinde veya belirlenen sahalarda, gerçekleşen ve beklenen hava hadiselerini kapsar. GAMET Saha Tahminleri ise yer seviyesi ile FL150 arasındaki seviyeyi ve rotayı kapsar. AIRMET mesajlarını desteklemek amacıyla kullanılırlar [38]. Meydan ihbarları, SIGMET mesajları, AIRMET

¹Türk AIP’sine göre gece, günbatımından yarım saat sonrası ve gündoğumun’dan yarım saat öncesini kapsayan süredir [56].

mesajları ve GAMET mesajları gibi önemli meteorolojik raporların hazırlanmasını ve yayınlamasını gerektiren önemli hava hadiseleri sırasıyla EK 1 - 4'te verilmiştir [38].

2.2.1. Rüzgâr

Atmosferdeki yüksek basınç alanından alçak basınç alanına doğru oluşan hava akımı, rüzgâr olarak tanımlanmaktadır. Bu oluşumun temel kaynağı, tanımından da anlaşılacağı üzere bölgeler arasındaki atmosfer basıncı farklılıklarıdır. Bu basınç farkının büyüklüğü hava akımı hızını belirler ve rüzgârın şiddetini oluşturur.

Uçaklar tasarımlarına göre rüzgârlardan farklı farklı etkilenirler. Rüzgâr durumu özellikle kalkış ve iniş evrelerinde, pist yönünün de sabit olması nedeniyle, göz önünde bulundurulması gereken bir husustur [59]. Yan rüzgârlar uçağın kararlılığını etkilemekte ve dengesini bozabilmektedir. Yan rüzgârlar, küçük hafif eğitim uçaklarında askerî uçaklara ve büyük ağır uçaklara kıyasla daha etkili olmaktadır. Birçok uçuş eğitim organizasyonunda kullanılan, Anadolu Üniversitesi envanterinde de yer bulmuş Cessna 172 SP uçakları 15 kt ve TB-20 Trinidad 25 kt yan rüzgâr bileşenleri içerisinde güvenli uçuşlarını gerçekleştirebilmektedirler [60, 61]. Cessna 172 SP ve TB-20 Trinidad uçaklarının açığa bağlı rüzgâr bileşenleri Şekil 2.1(a)'da ve Şekil 2.1(b)'de verilmiştir.


2.2.2. Rüyet

Belirli bir nesnenin görülebileceği en uzak mesafe “Görüş” veya “Rüyet” olarak tanımlanmaktadır. Sis, duman, pus, yağış gibi çeşitli hava hadiseleri rüyeti olumsuz etkileyebilmekte ve uçuşa elverişlilik için gerekli şartların sağlanamamasına bağlı olarak VFR uçuş mümkün olamamaktadır [38, 54, 59].


2.2.3. Bulutlar

Bulut; kalınlığına bağlı olarak beyaz, gri ve siyah renklerde görülebilen, su damlacıkları ve buz kristalleri içeren hava kütesidir. Şekil 2.3'de irtifâ ve türlerine göre verilen bulutlar, Tablo 2.4'de özetlenmiştir.

Stratus bulutları içerisinde ve altında hafif türbülans görülmekte ve bu bulutların alt tarafında çisentiye bağlı olarak, rüyet düşmektedir. 50 ft altında oluşan stratus bulutları sis olarak isimlendirilmektedir. Tabanlarının alçak oluşu nedeniyle bulut içinde uçuşlar tehlikelidir. Stratocumulus bulutlarında genellikle hafif ve orta şiddette türbülans ve 0° C'nin altında şiddetli buzlanma görülmektedir. Altostratus bulutlarında buzlanma ve hafif türbülans görülmektedir. Altocumulus bulutlarında



(a) Cessna 172 SP rüzgâr bileşenleri



(b) TB-20 Trinidad rüzgâr bileşenleri

Şekil 2.1. Cessna 172 SP ve TB-20 Trinidad uçaklarına ait rüzgâr bileşenleri

Tablo 2.4. Bulut türleri

Alçak bulutlar	Orta bulutlar	Yüksek bulutlar
$\leq 2,000$ m	2000~7,000 m	$\geq 7,000$ m
Su damlacıkları	Su damlacıkları	Buz kristalleri
Yavaş buzlanma	Buzlanma	Buzlanmaya sebep olmaz
Hafif türbülans	Hafif türbülans	Türbülans görülmez
Stratus (St)	Altostratus (As)	Cirrocumulus (Cc)
Stratocumulus (Sc)	Altostratus (As)	Cirrostratus (Cs)
Cumulus (Cu)†	Nimbostratus (Ns)	Cirrus (Ci)
Cumulonimbus (Cb)†		

† Dikine gelişimli bulutlar: Yerden yüksekliği ≤ 500 ft, düşük rüyet, şiddetli buzlanma ve şiddetli türbülans

hafif türbülans ve zaman zaman da buzlanma görülmektedir Bununla birlikte bulut içinde rüyet düşüktür. Nimbostratus bulutlarında düşük rüyet, şiddetli türbülans ve buzlanma görülmektedir. Bu nedenle havacılık faaliyetleri için tehlike oluşturmaktadırlar. Yüksek irtifâ bulutlarında ise türbülans ve buzlanma görülmemektedir. Dikey gelişimli cumulus ve cumulonimbus bulutları havacılık faaliyetleri açısından büyük tehlike oluşturmaktadırlar. Bu bulutlarda buzlanma ve dikine gelişimli türbülans görülür. Özellikle cumulonimbus bulutları fırtına ve gök gürültüsüyle birlikte bulunurlar. Bulut altında yağış görülür ve buzlanma şiddetlidir. Pilotların en çok dikkate aldıkları bulut türüdür. Cumulonimbus (CB) ve Cumulus Congestus ya da


TCU (Towering Cumulus) dikine gelişme gösteren konvektif bulutları, METAR raporlarında daima rapor edilirler [37, 38, 43, 54, 59, 62, 63].

Bulut kapalılık oranı, gökyüzünün bulutlar tarafından ne düzeyde kaplandığının 8 okta üzerinden bir ifadesidir [38, 59]. Kapalılık oranları, derecelerine göre Tablo 2.5’de gösterildiği üzere isimlendirilmektedir.

Tablo 2.5. Bulut kapalılık oranları

SKC	Açık (Sky clear)	0/8
FEW	Az (Few)	1/8 - 2/8
SCT	Dağınık (Scattered)	3/8 - 4/8
BKN	Parçalı (Broken)	5/8 - 7/8
OVC	Kapalı (Overcast)	8/8


Ölçüm tekniği Şekil 2.2’de tasviren anlatılmıştır. Şekle göre FEW (2/8) ve SCT (3/8) kapalılık oranında bulutlar görülmektedir.



Şekil 2.2. Bulut kapalılık oranı

2.2.4. Yağış

Yağış, nemin yoğunlaşmaya bağlı olarak çişenti (DZ, drizzle), yağmur (RA, rain), kar (SN, snow) veya dolu (GR, hail) şeklinde yeryüzüne intikâlidir. Hâlihazırda hava sıcaklığı, yoğunlaşmanın başladığı işba sıcaklığına eriştiğinde bahsi geçen yağış şekillerinden birisinin oluşacağı anlamını taşır. Yağışlar rüyeti, pist yüzeyini ve uçağın gövdesini etkilemeleri nedeniyle havacılık faaliyetleri açısından tehlike oluşturlar. Yine oraj ve şiddetli sağanak yağışa bağlı olarak rüzgâr kesmesi ve kuvvetli hamle oluşumu nedeniyle bir diğer tehlike kaynağıdır. Yağışlar düşük sıcaklıklarla birlikte buzlanmaya neden olurlar. Böylelikle pist yüzeyinin kalkış ve inişe müsait olmaması veya kanatlarda aerodinamik şeklin bozulması şeklinde tehlike oluşturlar.



Şekil 2.3. Bulut türleri
Kaynak: [64]

Çisenti, genellikle sis ile birlikte görülen su partikülleridir. Yağmur, buz kristallerinin irtifâ azaldıkça sıcaklığın artması hâlinde form değiştirmesi ve sıvı hâlde yeryüzüne düşmesidir. Kar, buz kristallerinden oluşan büyük yapıların, katı hâlde yeryüzüne düşmesidir. Yer seviyesinin $+4^{\circ}\text{C}$ 'nin altında bir sıcaklık değerinde olması hâlinde görülür. Dolu, buz kristallerinin kuvvetli dikey akımların etkisinde bulut içerisinde irtifâ azaldıkça aşırı soğumuş su damlacıkları ile çarpışmalarına bağlı olarak büyümeleri ve katı hâlde yeryüzüne düşmeleridir. Tablo 2.6'de bulutlar ve yağış türleri arasındaki ilişki gösterilmektedir [38, 59, 65].

Tablo 2.6. Bulutlar ve yağış türleri

Yağış\Bulut	As	Ns	Sc	St	Cu†	Cb†
Yağmur	*	*	*		*	*
Çisenti				*		
Kar	*	*	*	*	*	*
Kar paletleri			*		*	*
Dolu						*
Küçük dolu						*
Buz paletleri	*	*				
Buz grenleri				*		

† Yağmurla karışık yağış


2.2.5. Gündoğumu-günbatımı

Dünya'nın Güneş'e olan uzaklığı sabit değildir. Dünya'nın eksen eğikliği ve yıllık hareketi sonucu gece-gündüz süresi ve Güneşin doğuş-batış saatleri sürekli değişmektedir. 21 Mart ve 23 Eylül tarihlerinde gece ve gündüz birbirine eşitken, 21 Aralık'ta en kısa gün en uzun gece, 21 Haziranda ise en uzun gün ve en kısa gece yaşanmaktadır. Dünya'nın yıllık hareketi Şekil 2.4'de tasviren anlatılmıştır. Şekil 2.5'de ise enlemin ve zamanın bir fonksiyonu olarak gündüz süresi kontur grafiğinde gösterilmiş ve Hasan Polatkan Havaalanı'nın bulunduğu $39^{\circ}48'45''\text{N}$ enlem konumu belirtilmiştir.


2.2.6. Uçuşa elverişlilik şartları

Meteorolojik hadiseler rapor edilirken bazı limit değerler kullanılmaktadır. Bu hava hadiseleri raporlanırken limit şartların sağlanmış olması gerekmektedir. Örneğin BLSN hadisesi raporlanmışsa rüzgâr 10 kt üzerindedir veya SS hadisesi rapor edilmişse rüzgâr 27 kt üzerindedir. Limit şartları EK-5'de verilmektedir.

Uçuşa elverişlilik kriterleri; VFR uçuş prosedürleri, havacılığı etkileyen önemli meteorolojik hadiseler, mevcut çalışmalar ve pilot tecrübeleri de göz önünde bulundurularak bir uçuş eğitim organizasyonu olarak Anadolu Üniversitesi Pilotaj Bölümü



Şekil 2.4. Dünya'nın yıllık hareketi ve sonuçları



Şekil 2.5. Enlemlere göre gündüz süreleri

Kaynak: [66]

ve Hasan Polatkan Havaalanı temel alınarak belirlenmiştir. Buna göre; vaktin, gün-doğumundan yarım saat önce ve günbatımından yarım saat sonra zaman aralığında olup olmadığı, iniş ve/veya kalkışların yapıldığı yön göz önünde bulundurulmak kaydıyla yan rüzgârların hızı ve hamle durumu, bulut kapalılığının 5/8 okta'dan fazla olması, bulut taban yüksekliğinin 3,000 ft'den az olması, oraj, cumulonimbus ve cumulus congestus bulutlarının varlığı, meydan ihbarlarını gerektiren önemli hava hadiseleri, şiddetli sağanak yağışlar, rüyetin 5,000 m'den düşük olması ve sıcaklığın 5° C 'den düşük olması durumları değerlendirilerek, bahsi geçen durumların oluşması halinde eğitim için uçuşa elverişlilik şartlarının sağlanmadığı yönünde saatlik uçuşa elverişlilik çıkarımları yapılmıştır.

3. İSTATİSTİKİ SONUÇLAR

3.1. Görerek Uçuşa Elverişli Zaman Aralığı

Yapılan çalışma kapsamında hesaplanan, uçuşa uygun zaman aralığı olan gün-doğumu -30 dk ve günbatımı +30 dk toplam zamanlarının aylara ve yıllara göre dağılımı Tablo 3.1’de gösterilmiştir. VFR uçuş prosedüründe belirtilen 30 dk’lık süre eklemeleri toplamda 1 saat fark yaratacağı için Şekil 2.5’ten elde edilen grafiksel değerlere çok yakındır ve uyumludur. Tablo meteorolojik şartların elvermesi halinde uçuş için kullanılabilecek zaman aralığını göstermektedir.

Tablo 3.1. VFR prosedürünce öngörülen uçuşa elverişli zaman aralığı (saat)

	2009	2010	2011	2012	2013	2014	Ortalama	Günlük Ortalama
Oca	332.55	332.38	332.18	332.00	332.57	332.42	332.35	10.72
Şub	327.92	327.67	327.47	339.48	327.97	327.75	329.71	11.78
Mar	401.77	401.52	401.28	402.32	401.88	401.53	401.72	12.96
Nis	428.33	427.72	427.57	428.58	428.40	427.77	428.06	14.27
May	476.83	476.55	476.38	477.08	476.85	476.57	476.71	15.38
Haz	478.30	478.22	478.20	478.32	478.28	478.23	478.26	15.94
Tem	485.52	485.70	485.80	485.25	485.48	485.68	485.57	15.66
Ağu	455.43	455.70	456.02	455.12	455.38	455.68	455.56	14.70
Eyl	403.20	403.52	403.83	402.87	403.18	403.47	403.34	13.44
Eki	376.37	376.77	377.00	375.97	376.30	376.75	376.53	12.15
Kas	330.00	330.22	330.42	329.80	330.00	330.22	330.11	11.00
Ara	322.70	322.72	322.73	322.58	322.72	322.73	322.70	10.41

3.2. Uçuşa Elverişlilik

Uçuş eğitim organizasyonları planlamalarını meteorolojik hadiselerin dışında bir takım olguları da göz önüne alarak, ihtiyaçlarına göre düzenlemektedirler. Bu planlama sürecinde öğretmen pilot, aday pilot ve uçak durumları da dikkate alınmaktadır. Anadolu Üniversitesi Pilotaj Bölümü’nde meteorolojik hadiselerle ilgili olarak, planlamalar yapılırken en az 2 saat sorti süresi ve bu sorti süresinden sonra güvenlik maksatlı olmak üzere en az 1 saat boyunca uygun hava koşullarının korunuyor olması durumu göz önünde bulundurulmaktadır. Tablo 3.2’de aylara göre günlük en az uçuşa elverişli saate karşılık 6 yıl boyunca ortalama gün sayısı dağılımı verilmiştir. Örneğin; günlük en az uçuşa elverişli 5 saati olan gün sayısı, altı yıl boyunca 1522 gün ve bu altı yılın ortalaması olmak üzere senelik 254 güne karşılık gelmektedir. Tablo 3.3’de ise aylar üzerinden 6 yıl boyunca elde edilen ortalamalar yer almaktadır. Uçuşa elverişli saatlerin yıllara ve aylara göre dağılımları ve uçuşa elverişli günlerin yıllara ve aylara göre dağılımları sırasıyla EK-6 ve EK-7’de verilmektedir.

Tablo 3.2. 2009 - 2014 Toplam ve ortalama uçuş elverişli gün sayısı

Elverişli saat	0 ≥	1 ≥	2 ≥	3 ≥	4 ≥	5 ≥	6 ≥	7 ≥	8 ≥
Toplam gün	2191	1812	1734	1655	1589	1522	1437	1353	1256
Ortalama gün	365	302	289	276	265	254	240	226	209
Elverişli saat	9 ≥	10 ≥	11 ≥	12 ≥	13 ≥	14 ≥	15 ≥	16 ≥	17 ≥
Toplam gün	1158	1061	932	791	655	508	397	157	0
Ortalama gün	193	177	155	132	109	85	66	26	0

Tablo 3.3. 2009 - 2014 Ortalama uçuş elverişli gün sayısı

	0 ≥	1 ≥	2 ≥	3 ≥	4 ≥	5 ≥	6 ≥	7 ≥	8 ≥	9 ≥	10 ≥	11 ≥	12 ≥	13 ≥	14 ≥	15 ≥	16 ≥
Ocak	31	16	15	12	11	10	9	8	6	5	4	2	0	0	0	0	0
Şubat	28	19	17	15	14	12	10	9	8	7	6	4	3	0	0	0	0
Mart	31	23	20	18	18	17	16	15	13	12	11	10	9	5	1	0	0
Nisan	30	27	25	24	23	22	21	19	17	16	14	12	9	7	6	3	0
Mayıs	31	29	28	27	26	24	22	20	19	17	16	14	13	12	11	10	0
Haziran	30	30	29	28	28	27	27	25	23	22	20	18	17	16	15	14	12
Temmuz	31	31	31	31	31	30	30	30	29	29	28	28	26	25	23	22	14
Ağustos	31	31	31	31	31	30	30	30	29	28	28	27	27	25	24	19	0
Eylül	30	29	29	28	27	27	26	25	25	23	22	20	19	16	5	0	0
Ekim	31	27	26	25	24	22	21	20	18	16	14	12	10	4	0	0	0
Kasım	30	23	22	21	21	20	19	18	17	14	11	7	1	0	0	0	0
Aralık	31	18	17	16	14	13	10	9	7	6	4	3	0	0	0	0	0
Toplam	365	302	289	276	265	254	240	226	209	193	177	155	132	109	85	66	26

4. YÖNTEM

Bu çalışmada uçuşa elverişliliğin kestirim modelini gerçekleştirebilmek için hava olaylarının Markov süreci olduğu, belirli bir yerde ve zamanda sınırlı sayıdaki önceki durumların bir sonucu olduğunu varsayılmıştır. Dördüncü bölüm kestirim çalışmalarının gerçekleştirildiği 18,240 yapay sinir ağı yapısını ele almakta ve araştırmacıları yönlendirmeye yönelik ek bilgiler içermektedir.

4.1. Yapay Sinir Ağları


Yapay sinir ağları, nöronların biyolojik işleyişlerinden esinlenerek geliştirilmiş, dağıtık hafızalı yapılardır. Eğitim sonucunda öğrenilen bilgi, ağ ağırlıkları üzerinde barındırılır. Bu bilgi neticesinde ağ, ilk defa karşılaştığı bilgiye bile bir çıktı üretebilir. Doğrusal olmayan (nonlineer) bir yapıya sahip oldukları için, işleyişi bilinmeyen sistemleri bile modellemede başarılı sonuçlar elde edilebilmektedir.

İnsan beyninin çalışmasına ait ilk çalışma 1892 yılında William James tarafından yayınlanmıştır. YSA'nın temelleri ise, Warren S. McCulloch ve Walter Pitts tarafından 1943 yılında atılmıştır. İlk yapılar bazı lojik işlemleri gerçekleştirebilen, eğitim aşaması olmayan yapılardı. 1949 yılında Donald Hebb, nörobiyolojik perspektiften öğrenme postülalarını ortaya attı. Bu postülalara dayanan Hebbian öğrenme kuralına göre ağ ağırlıklarının değerleri değiştirilmektedir. 1958 yılında Frank Rosenblatt, sınıflama kabiliyetli, eğitilebilen "perceptron"u geliştirdi. 1960 yılında Bernard Widrow ve Ted Hoff en küçük kareler öğrenme kuralıyla ADALINE'ı geliştirdiler. 1969 yılında Marvin Minsky ve Seymour Papert, tek katmanlı yapıların yetersizliklerini değerlendirdiler. Bu yıllarda Rosenblatt çok katmanlı yapılarla çeşitli çalışmalar yapmıştır. Fakat, o dönemde öğrenme kuralları henüz ortaya atılmamıştı. 1972 yılında Teuvo Kohonen ve James Anderson öğretmensiz öğrenme kurallarının temelini oluşturan, çağrışımlı bellek konulu birbirine benzer ayrı çalışmalar yaptılar. 1973 yılında Christoph von der Malsburg kendi kendini düzenleyebilen ağlar üzerine öncü çalışmaları yaptı. Çok katmanlı ağlar için geriyayılım algoritmasına (BPA) ilk olarak 1974 yılında Paul J. Werbos'un doktora tezinde rastlanmaktadır. 1977 yılında Shun-ichi Amari, geri dönüşümlü ağların (recurrent networks) temelini attı. 1982 yılında John Hopfield geri dönüşümlü ağlar üzerine detaylı bir çalışmayla çalışma prensiblerini ortaya koydu. 1982 yılında Teuvo Kohonen danışmansız, yarışmacı öğrenme kuralıyla sınıflandırma problemlerinde oldukça başarılı SOM (Self-Organizing Maps) yapılarını ortaya koydu. 1985 yılında D. Parker ve Y. LeCun, 1986 yılında D. E. Rumelhart, G. E. Hinton ve R. J. Williams tarafından geriyayılım algoritması birbirinden ayrı çalışmalarla ortaya kondu [67, 68]. Konu bir çok araştırmacı tarafından irdelenmekte ve geliştirilmeye devam edilmektedir.

Sınıflama, tahmin, modelleme ve filtreleme problemleri, YSA'larının başlıca uygulama alanlarıdır [69–72]. Dağıtık hafıza yapısı sayesinde çok sayıda bilgi az sayıda ağ ağırlıkları üzerinde saklanabilmekte fakat buna karşılık ağ çıktıları eğitimin niteliğine göre gerçek sonuçlara belirli bir hata düzeyinde yakınsanmış şekilde elde edilebilmektedir. YSA'lar şıkıştırma ve bileşenlerine ayırma kabiliyetlerine de sahiptirler. Problemin türüne göre ağ yapısı ve özellikleri belirlenmektedir. Ağ yapılarının farklı özelliklerle oluşturulabilmesi, problemin en iyi çözümünün ihtiyaca göre uygulamacı tarafından belirlenebilmesine olanak tanımaktadır.

4.1.1. Yapay sinir hücreleri ve MLP

Çok katmanlı ağlar nöronların birlikte paralel kullanılmalarıyla elde edilmektedir. YSA'nın tek bileşeni olan nöron Şekil 4.1'de verilmiştir. İterasyon, veri setinde bir anlık durumun değerlendirilmesi, epoch ise veri setinin tamamının değerlendirilmesini ifade eder.



Şekil 4.1. Yapay nöron hücresi

Şekil 4.1'a göre matematiksel olarak, j 'nci nörondaki i 'nci iterasyon:

$$v_j(i) = \sum_{k=1}^n (w_{jk}(i)x_k(i)) + b_j \quad (4.1)$$

ve

$$y_j(i) = f(v_j(i)) \quad (4.2)$$

şeklinde ifade edilir. Denklemler (4.1) ve (4.2)'de j değişkeni çok katlı yapılarda farklı nöronları ifade edebilmek için eklenmiştir. Çoğunlukla bütün nöronlarda aynı aktivasyon fonksiyonu kullanıldığı için f aktivasyon fonksiyonu indislenmemiştir. Girdilerin sayıca çok olmasından ziyade, girdi uzayının farklı örnekleri ihtiva etmesi önemlidir. Böylelikle YSA farklı girdiler karşısında nasıl çıktılar üreteceğini öğrene-

bilecektir. Çok sayıdaki benzer bilgilerle eğitilen YSA, farklı girdiler için anlamlı sonuçlar vermeyebilir. Ağırlıklar iteratif olarak gerçekleştirilen eğitim süresince değiştirilir ve beklenen değerle çıktı arasındaki farkın en aza indirilmesi amaçlanır. Şekil 4.1’de gösterilen eşik değer, aktivasyon fonksiyonunda ayırteilmek üzere sınıflamayı sağlayacak doğrunun ofset değerini ifade etmektedir. Şekil 4.2’de bu durum ifade edilmektedir. Şekil 4.1’e fazladan +1 değerli girdi vermekle bias kullanmak aynı işlevi görmektedir. Buna göre,

$$y_j(i) = f \left(w_{j0}(i) \times 1 + \sum_{k=1}^n w_{jk}(i)x_j(i) \right) \quad (4.3)$$


ve

$$y_j(i) = f \left(\sum_{k=0}^n w_{jk}(i)x_k(i) \right) \quad (4.4)$$

elde edilir. Bias özellikle geri dönüşümlü ağlarda çıktıların ayarlanabilmesinde daha da önem kazanmaktadır. Bilgisayar uygulamalarının geliştirilebilmesi ve basitliği temin için vektörel form kullanılmaktadır. Denklem (4.4)’ün vektörel formu (4.5) ile verilmiştir.

$$y_j(i) = f(\mathbf{w}_j^T(i)\mathbf{x}(i)) \quad (4.5)$$


Burada $\mathbf{x}(i) = [x_1(i), x_2(i), \dots, x_m(i)]^T$ ve $\mathbf{w}_j(i) = [w_{j1}(i), w_{j2}(i), \dots, w_{jm}(i)]^T$ ifadeleridir. Vektörel çarpma işlemi yapıldığında sistemi doğru modelleyebilmek için transpoze işlemi gerçekleştirilmiştir. Buna göre $\mathbf{x}(i)$ sütun ve $\mathbf{w}^T(i)$ satır vektörüdür.



Şekil 4.2. Sınıflama bölgeleri

Aktivasyon fonksiyonu, sürekli olmalıdır. İleri beslemeli ağlarda kullanılabilecek çok sayıda sürekli fonksiyon mevcuttur. Fakat, geri yayılım algoritmasının prensipleri gereği fonksiyon ayrıca türevlenebilir olmalıdır. Literatürde lineer, sigmoid ve


hiperbolik tanjant aktivasyon fonksiyonları sıklıkla kullanılmaktadır. Elliot aktivasyon fonksiyonu ise hiperbolik tanjant fonksiyonuna benzer aşırı işlem gücü istemeyen, kolay, hızlı bir yaklaşımdır [73, 74]. Hangi fonksiyonun seçilmesi gerektiğine yönelik bir kriter mevcut değildir. Ağıın verdiği öğrenme tepkilerine göre uygun olan bir fonksiyon seçilmelidir. Şekil 4.3’de bazı aktivasyon fonksiyonları gösterilmiştir.




Şekil 4.3. Aktivasyon fonksiyonları

Nöron hücrelerinin birlikte kullanılmalarıyla oluşturulan çok katmanlı ağlar (MLP) genel olarak Şekil 4.4 ve yapısal olarak Şekil 4.5’de gösterilmiştir.

Birden fazla sayıda gizli katmana sahip ağlar tasarlanabilmektedir. Uygulamalarda ise tek gizli katmana sahip ağlar da yeterli olmaktadır [13]. Bu durum MLP uygulamalarında geçerli olmakla birlikte gizli katman sayısının, geridönüşümlü ağlarda önemli olduğu bilinmelidir.



Şekil 4.4. MLP ağları genel yapısı



Şekil 4.5. Çok katmanlı yapılar

Denklem (4.6) MLP ağı çıktısını ifade etmektedir.

$$\begin{aligned}
 o_m(i) &= \sum_{j=1}^l (w_{mj}y_j(i)) + b_m \Rightarrow \\
 o_m(i) &= \sum_{j=1}^l w_{mj}f(\mathbf{w}_j^T(i)\mathbf{x}(i)) + b_m
 \end{aligned} \tag{4.6}$$

Girdi katmanı ve çıktı katmanı nöron sayısı, veri setine göre belirlenmektedir. Gizli katman sayısının belirlenmesine yönelik net bir kriter mevcut değildir ve tasarımcının denemeleri ile tayin edilmektedir. Fakat eğitim süresinin kısaltılması ve yapının uygulamaya çevrilmesi halinde sistem performansının en iyilenmesi için, mümkün olan en az nöron sayısının tespit edilmesi istenmektedir. Literatürde dört

önermeyle karşılaşmıştır.

Kalagirio ve Bojic çalışmalarında (4.7) ile verilen eşitliği mühendislik çalışmaları için önermektedirler [75].

$$l = \frac{n + m}{2} + \sqrt{\max i} \quad (4.7)$$

Denklem (4.7)'de l gizli katman hücre sayısı, n girdi sayısı, m çıktı sayısı ve $\max i$ ise öğrenme kalıpları sayısını ifade etmektedir.

Surreerattanan ve arkadaşları ise en uygun nöron sayısını sistematik bir şekilde tespit etmeyi amaçlamışlar ve az sayıda başlayan gizli katman nöronlarıyla (4.8)'de ifade edilen Bayes Bilgi Kriteri (BIC)'ne göre hesapladıkları sistem hatasının, (4.9) ile verilen belirli bir eşik seviyesine ulaşması halinde nöron sayısını arttırarak eğitimi tekrar etmişlerdir [13, 45].

$$BIC = \max i \times \ln MSE + P \times \ln(\max i) \quad (4.8)$$

$$\left| \frac{BIC(l+1) - BIC(l)}{BIC(l)} \right| \leq \varepsilon_1 \quad (4.9)$$

Denklem (4.8) ve (4.9)'da l gizli katman hücre sayısı, P model boyutu, ε_1 eşik değer ve $\max i$ ise öğrenme kalıpları sayısını ifade etmektedir.

Gizli katman hücre sayısının bulunmasına yönelik Kolmogorov teoremi kullanılarak bir gizli katmana sahip ağlarda lineer regresyon problemi açısından yaklaşılarak (4.10) eşitliği ortaya konulmuştur. [76, 77]. Denklemde l gizli katman hücre sayısı ve n girdi sayısını ifade etmektedir.

$$l = 2 \times n + 1 \quad (4.10)$$

Shamsuddin ve Darus ise enerji fonksiyonları üzerine yaptıkları çalışmada dört farklı sınıflandırma problemlerini içeren verisetlerinde (4.11) eşitliğini kullanmışlardır [77]. Denklemde l gizli katman hücre sayısı, n girdi sayısını ve m ise çıktı sayısını ifade etmektedir.


$$l = \sqrt{n \times m} \quad (4.11)$$

Çok sayıdaki girdinin bulunduğu yapılarda, normalizasyon işlemi önem kazanmaktadır. Farklı türdeki girdilerin değersel farklılıkları, ağın öğrenememesine yol açabilmektedir. Aslında farklı türdeki girdilerde değişimin ağ tarafından kıyaslanabilmesi açısından normalizasyon işlemine ihtiyaç duyulur. Normalizasyon işlemiyle girdiler arasında ölçeklendirme ve veriler üzerinde boyutsuzlaştırma gerçekleştirilmiş

olur. Literatürde Z-Score, Min-Max, Medyan, Sigmoid ve Logaritmik normalizasyon teknikleri en bilinenlerdir ve Min-Max sıklıkla uygulanmaktadır. Bu çalışma süresinde gerçekleştirilen denemelerde farklı normalizasyon teknikleriyle birlikte verinin niteliğinin bozulabildiği ve ağıın öğrenemediği görülmüştür. Eğitim süresince ağı ağırlıkları tespit edilene kadar, aktivasyon fonksiyonunun en yüksek ve en düşük değerlerinde verinin nisbî anlamını yitirmemesi için, aktivasyon fonksiyonu aralığından bir miktar küçük bir aralığa normalizasyon yapılması daha uygundur. Eğitimin gerçekleştirilebilmesi için veri türüne uygun teknik belirlenmelidir. Yavuz ve Deveci hava olayları ile ilgili farklı türdeki verilerle gerçekleştirdikleri çalışmalarında en iyi öğrenmenin Medyan ve Min-Max türlerinde gerçekleştirilen normalizasyon ile gerçekleştirildiği sonucuna ulaşmışlardır [78]. MLP ağları statik ağlardır. Yani çıkıştan girişe veya gizli katmandan girişe geribeslemeleri yoktur.

4.1.2. TDNN


TDNN (Time-Delay Neural Networks) ilk olarak Lang ve Hinton tarafından 1988 yılında ortaya atıldı. Statik ağıın (MLP, Radial Basis v.s.) dinamik bir şekilde kullanılması esasına dayanan hafızalı yapılardır [69]. Eğitimleri statik ağlardaki şekilde yapılmaktadır. Girdi katmanı çok boyutlu olabilmektedir. Yani her iterasyonda birden fazla sayıda girdi ile eğitim süreci gerçekleştirlebilmektedir. TDNN yapıları yüksek frekans değerlerini süzelebilmektedir. Bir nevi FIR filtreleme yapmaktadırlar. Ses tanıma gibi tanıma tabanlı uygulamalarda tercih edilmektedirler [67, 69]. TDNN özel bir ileri beslemeli ağı yapısıdır. Çok sayıda gizli katmana sahip olabilirler. Hava durumu tahminlerinde şiddetli yağmur gibi uzun dönemlerde düşük yoğunlukta gerçekleşen olayların ağı üzerindeki etkisini düzenlemede elverişlidirler [15].



Şekil 4.6. TDNN hücre yapısı


Şekil 4.6’de hücre yapısı ve Şekil 4.7 ile 4.8’de ise TDNN genel ve yapısal gösterimlerine yer verilmiştir. Şekil 4.6’deki yapı (4.12) ile ifade edilmiştir. MLP’den farklı olarak eşik terimi denklemden sabit bir girdi verilerek çıkarılamamaktadır. Çünkü zaman alanında (domen) belirli bir zarfla(pencere) ilerleyen girdi yapısı buna müsaade etmemektedir.

$$y_j(t) = f \left(\sum_{L=0}^p (\mathbf{w}_j^T(L) \mathbf{x}(t-L)) + b_j \right) \quad (4.12)$$



Şekil 4.7. TDNN ağı genel yapısı

Şekil 4.8 ile verilen ağ yapısı (4.13) ile açıklanmıştır. Burada $x(t)$ (4.5)’den farklı olarak p zarf boyutunda kendi geçmiş değerlerinden oluşmaktadır ve eşitlik $\mathbf{x}(t) = [x(t), x(t-1), \dots, x(t-p)]^T$ şeklinde ifade edilir.




Şekil 4.8. TDNN ağ yapısı


$$\begin{aligned}
 o_m(t) &= \sum_{j=1}^l (w_{mj} y_j(t)) + b_m \Rightarrow \\
 o_m(t) &= \sum_{j=1}^l w_{mj} f \left(\sum_{L=0}^p (\mathbf{w}_j^T(L) \mathbf{x}(t-L)) + b_j \right) + b_m \quad (4.13)
 \end{aligned}$$

4.1.3. Elman ağı

Elman 1990 yılında gizli katmandan girişe bir geribesleme uygulayan SRN (Simple Recurrent Network) yapısını önerdi. Kısmî geri dönüşümlü bir yapıya sahiptir. Yani geri dönüşümü gerçekleştiren ağlar eğitime katılmazlar ve ağırlık değerleri sabittir. Statik yapıli MLP ağlarıyla aynı şekilde eğitilirler ve ağırlık değerleri değiştirilirken geri dönüşüm ağırlıkları dikkate alınmazlar. Girişe orta katmandan gecikmeyle geribesleme yapmak dışında MLP ağlarından bir farkları yoktur. Böylelikle ağ yeni çıktıları üretmeden bir önceki durumu hakkında çıkış değerine katkıda bulunur. Sıralı katmanlara sahip olan yapılar RMLP (Recurrent Multilayer Perceptron) şeklinde adlandırılırlar. Bu yapılarda her gizli katmanın çıkışı yine kendisine bir girdi şeklinde tasarlanır [15, 67–69]. Şekil 4.9 ve 4.10’da Elman ağları genel ve yapısal gösterimleri verilmiştir.



Şekil 4.9. Elman ağları genel yapısı



Şekil 4.10. Elman ağları

Tek gizli katmana sahip Elman ağı (4.16) ifade edildiği şekilde denklemlendirilebilir. Burada geri besleme ağırlıklarının ($\hat{w}$) sabit olduğuna ve eğitim sırasında değiştirilmediğine dikkat edilmelidir.


$$y_j(t) = f \left(\sum_{k_1=1}^n w_{jk_1}(t) x_{k_1}(t) + \sum_{k_2=1}^l \hat{w}_{jk_2}(t) y_{k_2}(t-1) \right) + b_j \quad (4.14)$$

$$y_j(t) = f \left(\mathbf{w}_j^T(t) \mathbf{x}(t) + \hat{\mathbf{w}}_j^T(t) \mathbf{y}(t-1) \right) + b_j \quad (4.15)$$

$$\begin{aligned}
o_m(t) &= \sum_{j=1}^l (w_{mj}y_j(t)) + b_m \Rightarrow \\
o_m(t) &= \sum_{j=1}^l w_{mj} \left(f(\mathbf{w}_j^T(t)\mathbf{x}(t) + \hat{\mathbf{w}}_j^T(t)\mathbf{y}(t-1)) + b_j \right) + b_m \quad (4.16)
\end{aligned}$$

4.1.4. NARX

NARX (Nonlinear Auto-Regressive with Exogenous Inputs), statik MLP ile uyumlu ve nonlinear ilişkiler kurabilme kabiliyetine sahip geridönüşümlü bir ağıdır. Kontrol teorisinde nonlinear sistemleri modellemede kullanım alanı bulmuştur. Paralel ve paralel-seri bağlantılı yapılar sayesinde sistem modelleme yapabilmektedir. Elman ağlarından farklı olarak geri beslemeyi çıkıştan alır ve girişe iletir. Paralel bağlantılı ağlar tahmin sonucunu, paralel-seri bağlantılı ağlar ise gerçek verileri geribesleme olarak kullanırlar. Çok sayıda gizli katmana sahip olan yapılar kullanılabilir. NARX ağının genel ve yapısal gösterimleri Şekil 4.11 ve 4.12’de verilmiştir.




Şekil 4.11. NARX ağları genel yapısı

NARX ağı, MLP yapısının bir şekli olarak düşünüldüğünde, (4.17) eşitliği ile ifade edilebilir. Buna göre;

$$\mathbf{o}(t) = F(\mathbf{o}(t-1), \mathbf{o}(t-2), \dots, \mathbf{o}(t-\hat{p}), \mathbf{x}(t), \mathbf{x}(t-1), \dots, \mathbf{x}(t-p)) \quad (4.17)$$

$$y_j(t) = f \left(\sum_{L_1=0}^p \mathbf{w}_j^T(L_1)\mathbf{x}(t-L_1) + \sum_{L_2=0}^{\hat{p}} \hat{\mathbf{w}}_j^T(L_2)\mathbf{o}(t-L_2-1) + \omega_j\theta \right) + b_j \quad (4.18)$$

$$\begin{aligned}
o_m(t) &= \sum_{j=1}^l \left(w_{mj} y_j(t) \right) + b_m \Rightarrow \\
o_m(t) &= \sum_{j=1}^l \left[w_{mj} f \left(\sum_{L_1=0}^p (\mathbf{w}_j^T(L_1) \mathbf{x}(t - L_1)) \right. \right. \\
&\quad \left. \left. + \sum_{L_2=0}^{\hat{p}} (\hat{\mathbf{w}}_j^T(L_2) \mathbf{o}(t - L_2 - 1)) + \omega_j \theta + b_j \right) \right] + b_m
\end{aligned} \tag{4.19}$$



Şekil 4.12. NARX ağıları

4.1.5. Optimizasyon teknikleri

Çalışma kapsamında oluşturulan ağların eğitimleri LMA¹ (Levenberg-Marquardt Algorithm) ile gerçekleştirilmiştir. LMA, nonlinear en küçük kareler problemlerinde oldukça başarılıdır ve çözüme hızlı bir şekilde yakınsamaktadır. GDM (Gradient Descent Method) ve GNM (Gauss-Newton Method) optimizasyon metodlarının bir birleşimi şeklindedir ve güven bölgesi² yaklaşımına sahip bir Gauss-Newton optimizasyon metodudur. GDM'ye göre enerji fonksiyonun gradyanı alınarak en hızlı

¹Literatürde "DLS (Damped Least-Squares)" şeklinde de geçmektedir.

²Literatürde "Trust Region", "Restricted Step Method" şeklinde de geçmektedir.

artış gösterdiği yön bulunur ve negatif yönde parametreler güncellenerek iteratif bir şekilde minimum elde edilmeye çalışılır. GNM ise enerji fonksiyonunun çözüm bölgesinde kuadratik olduğunu kabul ederek lineer bir çözüm yaklaşımıyla türevinin sıfır olduğu minimumu, iteratif olarak bulmaya çalışır. LMA, enerji fonksiyonunun minimumuna negatif gradyan yönünde ilerleyerek yaklaşır ve lineer çözüm yaklaşımıyla iteratif olarak minimuma ulaşılır. Bazı parametre sayısının çok olduğu problemlerde GDM tek çözüm yolu olabilmektedir. Buna karşın çözüme yakınsamakta GNM kadar hızlı değildir. GNM optimizasyon tekniği ise sonuca hızla yakınsamakla birlikte parametre sayısına bağlı olarak sistemde daha fazla hafızaya gereksinim duymaktadır.

Enerji fonksiyonu olarak genellikle (4.20) kullanılmaktadır. Çalışmamızda kullandığımız enerji fonksiyonu (4.29)'de verilmektedir. Derin öğrenme (Deep Learning) çalışmalarında olasılıksal enerji fonksiyonları önem kazanmaktadır. Danışmanlı öğrenmede (4.21), (4.22), (4.23), (4.24) ve (4.25) kullanılan diğer enerji fonksiyonlarıdır. Denklemlerde d istenilen gerçek değerleri ve y ise çıkışlarını temsil etmektedir. Bernoulli Cost Function, Improved Cost Function gibi bir çok enerji fonksiyonu literatürde yer almaktadır [77, 79–85]. Burada önemli olan hata uzayında minimumun bulunabilmesidir. Bu çalışmada literatürde karşılaşılmamasından dolayı bazı enerji fonksiyonlarına yer verilmektedir.

- Sum of Error Squares

$$SSE = \sum_{i=1}^n (d_i - f_i)^2 \quad (4.20)$$

- Cross-Entropy (Deviance)

$$CE = - \sum_{i=1}^n d_i \ln(f_i) \quad (4.21)$$

- Exponential Cost Function

$$EXP = \tau \exp\left(\frac{1}{\tau} \sum_{i=1}^n (d_i - f_i)^2\right) \quad (4.22)$$

- Modified Cost Function

$$MM = \sum_{i=1}^n \frac{(d_i - f_i)^2}{2f_i(1 - f_i^2)} \quad (4.23)$$

- Minkowski- r metric

$$M = \frac{1}{r} \sum_{i=1}^n \left| d_i - f_i \right|^r \quad (4.24)$$

- Kullback-Leibler Divergence

$$KL = \frac{1}{2} \sum_{\mu=1}^m p(\mu) \sum_{i=1}^n \left| d_i - f_i \right|^r; \quad p(\mu) : \mu. \text{ giriş ihtimali} \quad (4.25)$$

4.1.5.1. *Levenberg-Marquardt algoritması*

Gauss-Newton metodu (GNM), Newton metodunun toplam karesel hata enerji fonksiyonuna uygarlanmış hâlidir. Newton metodunda yer alan ikinci dereceden türevlerden kurtularak hesaplama kolaylığı sağlanır. Enerji fonksiyonu 1/2 katı alınarak hesaplamalara dâhil edilmesi ile denklemlerin elde edilmesinin basitleştirilmesi amaçlanmaktadır.

Enerji fonksiyonu $\mathcal{E}(\mathbf{w}) : \mathfrak{R}^{N \times 1} \rightarrow \mathfrak{R}^+$ 'i minimum yapan $\mathbf{w} \in \mathfrak{R}^{N \times 1}$ ağırlık vektörünün bulunması kurulan ağ modelinin eğitilmesi anlamına gelmektedir. Analitik çözümün gerçekleştirilemediği problemlerde iteratif çözümler kullanılır. Bu iteratif çözümler algoritmik veya sezgisel olabilir. Newton metoduna göre $\mathbf{w}$ ağırlıklarına rastgele değerler atanır ve (4.26)'e göre iteratif çözüm aranır [67, 69, 86–89].

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \mathbf{H}_k^{-1} \mathbf{g}_k \quad (4.26)$$

İkinci dereceden türevleri içerisinde barındıran Hessian matris $\mathbf{H} \in \mathfrak{R}^{N \times N}$ (4.27)'de belirtildiği şekilde tanımlanmaktadır.

$$\mathbf{H} = \begin{bmatrix} \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_1^2} & \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_1 \partial w_2} & \cdots & \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_1 \partial w_N} \\ \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_2 \partial w_1} & \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_2^2} & \cdots & \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_2 \partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_N \partial w_1} & \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_N \partial w_2} & \cdots & \frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_N^2} \end{bmatrix} \quad (4.27)$$

Enerji fonksiyonunun gradyanı ise $\mathbf{g} \in \mathfrak{R}^{N \times 1}$ ise (4.28)'de verilmiştir.

$$\mathbf{g} = \left[\frac{\partial \mathcal{E}(\mathbf{w})}{\partial w_1} \quad \frac{\partial \mathcal{E}(\mathbf{w})}{\partial w_2} \quad \cdots \quad \frac{\partial \mathcal{E}(\mathbf{w})}{\partial w_N} \right]^T \quad (4.28)$$

Newton metodu gereği (4.26)'de belirtilen Hessian matris ve (4.28)'de belirtilen gradyan, $\mathbf{w} = \mathbf{w}(k)$ için hesaplanarak ağırlıklar üzerinde gerekli güncellemeler yapıldığında $\mathbf{w} = \mathbf{w}(k+1)$ yeni ağırlıkları bulunmuş olur. Böylelikle iteratif olarak enerji fonksiyonunun minimumuna doğru yakınsanır. Fakat Hessian matrisin tersini hesaplamanın uzun işlemler gerektirmesi ve ağ sayısı açısından da düşünüldüğünde Newton metodunun çözüme hızlı yakınsamasını anlamsız hâle getirmektedir.

Şekil 4.5 ve (4.29)'den hareketle enerji fonksiyonu (4.30) olarak ifade edilir.

$$\mathcal{E} = \frac{1}{2} \sum_{i=1}^n (d_i - f_i)^2 \quad (4.29)$$

$$\begin{aligned} \mathcal{E}(\mathbf{w}) &= \frac{1}{2} \sum_{q=1}^Q (\mathbf{d}_q - \mathbf{o}_q)^T (\mathbf{d}_q - \mathbf{o}_q) \\ &= \frac{1}{2} \sum_{q=1}^Q \sum_{h=1}^m (d_{qh} - o_{qh})^2 \end{aligned} \quad (4.30)$$

Denklem (4.30)'da $\mathbf{d}$ istenilen gerçek çıkışlar, $\mathbf{o}$ ağ çıkışı, Q eğitim veri sayısı, m ağ çıkış sayısı ve $\mathbf{w}$ ağ içerisindeki bütün ağırlıkların vektörünü ifade etmektedir. Newton metoduna (4.26) enerji fonksiyonunu (4.30) uygulayarak elde edilecek denklemlerdeki Hessian matrisinden kurtularak basit bir şekilde ifade edilmesi, metodun karmaşık problemlere basit bir çözüm sunmasını sağlayacaktır. Denklem (4.26)'de

$$\mathbf{H}_k = \nabla^2 \mathcal{E}(\mathbf{w})|_{\mathbf{w}=\mathbf{w}(k)} \quad (4.31)$$

$$\mathbf{g}_k = \nabla \mathcal{E}(\mathbf{w})|_{\mathbf{w}=\mathbf{w}(k)} \quad (4.32)$$

eşitliklerini ifade etmektedir. $P = mQ$ tanımını yaparak (4.30)'u basitleştirirsek

$$\begin{aligned} \mathcal{E}(\mathbf{w}) &= \frac{1}{2} \sum_{p=1}^P (\mathbf{d}_p - \mathbf{o}_p)^2 \\ &= \frac{1}{2} \sum_{p=1}^P e_p^2 \end{aligned} \quad (4.33)$$

elde edilir.

Jacobian matris $\mathbf{J} \in \mathbb{R}^{P \times N}$ (4.34)'de belirtildiği şekilde tanımlanmaktadır.

$$\mathbf{J} = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \cdots & \frac{\partial e_1}{\partial w_N} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \cdots & \frac{\partial e_2}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_P}{\partial w_1} & \frac{\partial e_P}{\partial w_2} & \cdots & \frac{\partial e_P}{\partial w_N} \end{bmatrix} \quad (4.34)$$

Enerji fonksiyonunun (4.33) j 'inci ve k, j 'inci elemanları için birinci ve ikinci dereceden türevleri sırasıyla (4.35) ve (4.36)'de verilmiştir.

$$\frac{\partial \mathcal{E}(\mathbf{w})}{\partial w_j} = \sum_{p=1}^P e_p \frac{\partial e_p}{\partial w_j} \quad (4.35)$$

$$\frac{\partial^2 \mathcal{E}(\mathbf{w})}{\partial w_k \partial w_j} = \sum_{p=1}^P \frac{\partial e_p}{\partial w_k} \frac{\partial e_p}{\partial w_j} + e_p \frac{\partial^2 e_p}{\partial w_k \partial w_j} \quad (4.36)$$

Buradan hareketle enerji fonksiyonunun (4.33) j 'inci ve k, j 'inci elemanları için gradyeni ve Hessian'ı (4.37) ve (4.38) şeklinde ifade edilir.

$$\nabla \mathcal{E}(\mathbf{w}) = \sum_{p=1}^P e_p \nabla e_p \quad (4.37)$$

$$\nabla^2 \mathcal{E}(\mathbf{w}) = \sum_{p=1}^P \left(\nabla e_p \nabla e_p^T + e_p \nabla^2 e_p \right) \quad (4.38)$$

Enerji fonksiyonunun gradyeni, matris formda (4.39) şeklinde elde edilir.

$$\begin{aligned} \mathbf{g} &= \frac{\partial \mathcal{E}(\mathbf{w})}{\partial \mathbf{w}} \\ &= \frac{1}{2} \begin{bmatrix} \frac{\partial \sum_{p=1}^P e_p^2}{\partial w_1} \\ \frac{\partial \sum_{p=1}^P e_p^2}{\partial w_2} \\ \vdots \\ \frac{\partial \sum_{p=1}^P e_p^2}{\partial w_N} \end{bmatrix} = \begin{bmatrix} \sum_{p=1}^P e_p \frac{\partial e_p}{\partial w_1} \\ \sum_{p=1}^P e_p \frac{\partial e_p}{\partial w_2} \\ \vdots \\ \sum_{p=1}^P e_p \frac{\partial e_p}{\partial w_N} \end{bmatrix} \\ &= \mathbf{J}^T \mathbf{e} \end{aligned} \quad (4.39)$$

Benzer yaklaşımla Hessian matrisi (4.34) açısından (4.40) şeklinde ifade edilebilir.

$$\nabla^2 \mathcal{E}(\mathbf{w}) = \mathbf{J}^T \mathbf{J} + \mathbf{S} \quad (4.40)$$

İkinci dereceden türev matrisi $\mathbf{S} \in \Re^{N \times N}$ (4.41) enerji fonksiyonu minumuna yaklaştıkça ihmal edilebilecek şekilde küçülecektir. Bu yüzden $\nabla^2 \mathcal{E}(\mathbf{w}) \approx \mathbf{J}^T \mathbf{J}$

yaklaşımı kullanılabilir.

$$\mathbf{S} = \sum_{p=1}^P e_p \nabla^2 e_p \quad (4.41)$$

$$\mathbf{H} \approx \mathbf{J}^T \mathbf{J} \quad (4.42)$$

Burada (4.42)'in newton metoduna göre iterasyonlarda tersinin alınması gerekmektedir. Matrisin determinantının sıfır olması gibi tersinin alınamayacağı durumların önüne geçebilmek için çok küçük bir μ sayısı ve uygun boyutlu $\mathbf{I} \in \Re^{N \times N}$ birim matrisi $\mu \mathbf{I}$ eklenir.

$$\mathbf{H} \approx \mathbf{J}^T \mathbf{J} + \mu \mathbf{I} \quad (4.43)$$

Newton metodunu (4.26)'de elde edilen (4.39) ve (4.43)'in yerine konularak tekrar üretilmesiyle (4.44)'ya ulaşılır.

$$\mathbf{w}(k+1) = \mathbf{w}(k) - [\mathbf{J}_k^T \mathbf{J}_k + \mu_k \mathbf{I}]^{-1} \mathbf{J}_k^T \mathbf{e}_k \quad (4.44)$$

Burada μ_k sıfıra yakın bir değer aldıkça $\mu_k \mathbf{I}$ ihmâl edilebilecek bir duruma gelir ve (4.44) Newton metoduna (4.45) yakınsar. Büyük değerler alması hâlinde ise daha çok Gradyan metoduna (4.46) benzemektedir

$$\begin{aligned} \mathbf{w}(k+1) &\approx \mathbf{w}(k) - [\mathbf{J}_k^T \mathbf{J}_k]^{-1} \mathbf{J}_k^T \mathbf{e}_k \\ &\approx \mathbf{w}(k) - \mathbf{H}_k^{-1} \mathbf{g}_k \end{aligned} \quad (4.45)$$

$$\begin{aligned} \mathbf{w}(k+1) &\approx \mathbf{w}(k) - [\mu_k \mathbf{I}]^{-1} \mathbf{J}_k^T \mathbf{e}_k \\ &\approx \mathbf{w}(k) - \frac{1}{\mu_k} \mathbf{J}_k^T \mathbf{e}_k \\ \alpha_k &= \frac{1}{\mu_k} \Rightarrow \\ \mathbf{w}(k+1) &\approx \mathbf{w}(k) - \alpha_k \mathbf{g}_k \end{aligned} \quad (4.46)$$

Başlangıçta öğrenme parametresi μ_k küçük bir değer seçilerek Gauss-Newton metoduna yakın tutulur ve ağırlık güncellemelerinden sonra hesaplanan yeni hata ile eski hatanın durumuna göre eğitim sırasında dinamik olarak değiştirilir. Eğer yeni hata büyükse güncellenen ağırlıklar geri alınır ve μ_k arttırılarak Gradyan metoduna yakınsanır. Eğer yeni hata küçükse daha da küçültülerek Gauss-Newton metoduna yakınsanma sağlanır. Böylelikle Gauss-Newton metodunun minimuma hızlı yakınsama ve Gradyan metodunun hassas ayarlama ile çözüm çevresinde salınım yapılmasına karşı avantajları kullanılmış olur.

Literatürde temel yaklaşımlar üzerine oldukça çalışılarak gerek kararlılığın artırılması gerek yakınsama hızının arttırılmasına yönelik bir çok geliştirmeler yapılmıştır. Bu nedenle temel yaklaşımların oldukça fazla varyasyonları mevcuttur. Tablo 4.1’de bazı metodlara ilişkin bilgiler verilmektedir.


Tablo 4.1. Farklı algoritmalara ilişkin özellikler

Algoritma	Kural	Yakınsama	Hesaplama yöntemi
Gradyan	$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k \mathbf{g}_k$	kararlı, yavaş	Gradyan
Momentumlu Gradyan	$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k \mathbf{g}_k + \rho[\mathbf{w}_k - \mathbf{w}_{k-1}]$	kararlı, yavaş	Gradyan
Newton	$\mathbf{w}_{k+1} = \mathbf{w}_k - \mathbf{H}_k^{-1} \mathbf{g}_k$	kararsız, hızlı	Gradyan, Hessian
Gauss-Newton (GNA)	$\mathbf{w}_{k+1} = \mathbf{w}_k - [\mathbf{J}_k^T \mathbf{J}_k]^{-1} \mathbf{J}_k^T \mathbf{e}_k$	kararsız, hızlı	Jacobian
Levenberg-Marquardt (LMA)	$\mathbf{w}_{k+1} = \mathbf{w}_k - [\mathbf{J}_k^T \mathbf{J}_k + \mu_k \mathbf{I}]^{-1} \mathbf{J}_k^T \mathbf{e}_k$	kararlı, hızlı	Jacobian
Neuron-by-Neuron (NBN)	$\mathbf{w}_{k+1} = \mathbf{w}_k - \mathbf{Q}_k^{-1} \mathbf{g}_k$	kararlı, hızlı	Quasi Hessian


Kaynak: [89, 90]

4.1.6. Geri yayılım algoritması


Geri yayılım algoritması, en az üç katmandan oluşan ağ yapılarında ve danışmanlı öğrenmede kullanılırlar. Geri yayılım algoritması, ağ çıkışları ile istenen çıkışlar arasındaki hatanın hesaplanarak ağ ağırlıklarının bu hatayı küçültecek şekilde güncellenmesi esasına dayanır. İleri doğru besleme ve geriye doğru yayılım yapılacağı için bir katmandaki hücre aynı katmanda bir hücreye bağlı olmamalıdır. Öncelikle gizli katman hücreleri üzerinden ağ çıktıları hesaplanır Şekil 4.13. Çıkışlar için hata hesaplamaları Şekil 4.14 ve gizli katman hücreleri için hata hesaplamaları Şekil 4.15 yapılır. Çıkış katman hücrelerinin ağırlıklarından başlanır Şekil 4.16 ve giriş katmanına doğru gizli katman hücrelerinin ağırlıkları güncellenerek Şekil 4.17 işlemler yinelenir. Böylelikle her iterasyonda ağ ağırlıkları çıkışlar üzerindeki hatayı azaltacak şekilde güncellenmektedir [67, 69, 70, 86, 89, 90]. Literatürde bu algoritma üzerinde birçok modifikasyon yapılarak öğrenme hızı iyileştirilmeye çalışılmıştır.




Şekil 4.13. Ağın ileri beslenmesi



Şekil 4.14. Çıkış hücreleri için hata hesaplamaları




Şekil 4.15. Gizli katman hücreleri için hata hesaplamaları



Şekil 4.16. Çıkış hücreleri için ağ güncellemeleri

4.1.7. Performans ölçümleri

İstatistik ve mühendislik çalışmalarında verilerin anlamlandırılması ve kıyaslanabilmesi için farklı amaçlara ve farklı veri seti tiplerine yönelik testler yaygın olarak kullanılmaktadır. Çalışmamızda oluşturulan modellerin kestirim sonuçlarını amaçlanan gerçek verilerle kıyaslayabilmek ve birbirlerine göre bir başarı ilişkisi



Şekil 4.17. Gizli katman hücreleri için ağ güncellemeleri

ortaya koyabilmek için MAE, MSE, RMSE, $\rho(r)$ ve R^2 testleri kullanılmış olup sırasıyla (4.47), (4.48), (4.49), (4.50) ve (4.51)'de hesaplanmalarına yönelik denklemler verilmektedir. MSE ile RMSE ve ρ ile R^2 birbirleriyle yakın ilişkili olmaları ve literatürde sıklıkla yer almalarından hareketle çalışmaya dahil edilmiş ve ilişkileri ise aşağıda açıklanmıştır. Lineer değerlendirmede kullanılan ölçütler, nonlinear verilerde bütünüyle aynı anlamları karşılayamamakta fakat bir fikir ortaya koyabilmektedir. MSE'nin veri biriminin karesi cinsinden olduğu ve değerlendirmelerde fikir ortaya koyduğu, dikkat edilmesi gereken bir diğer husustur. Hatanın veri birimi açısından değerlendirilmesi ise RMSE ile olanaklıdır. Denklemlerde d istenilen gerçek değerleri ve f ise kestirim değerlerini temsil etmektedir [13, 15–17, 34, 36, 42, 50, 91–97].

MAE (Mean Absolute Error) veya MAD (Mean Absolute Deviation), kestirim sonuçları ve gerçek veriler arasındaki mutlak hataların ortalamasıdır. Veri setinin sayısal sınırlarına göre ölçüm sonuçları farklılık göstermektedir ve sonucun sıfıra yakın olması eğitim performansının kalitesinin bir göstergesidir. Yüksek frekanslı da olsa büyük kestirim hataları performans sonuçlarını olumsuz etkiler. Örneğin, bütün kestirim boyunca çapraz korelasyon yüksek olsa bile anlık bir yüksek kestirim hatası, performans sonuçlarında anlık hata büyüklüğü nisbetinde fark oluşturur. Hataların mutlak değeri alınarak gerçek veriden fazla veya eksik kestirim yapılmasını bir hata olarak değerlendirmek olanaklı olmuştur.

$$MAE = \frac{1}{n} \sum_{i=1}^n |d_i - f_i| \quad (4.47)$$

MSE (Mean Squared Error) veya MSD (Mean Squared Deviation), karesel ifadesinin bir sonucu olarak sürekli pozitif değerler alır ve değerlendirmelerde en iyi sonuç için sıfıra yakın olması istenir. Veri setinin sayısal sınırları, performans sonuçları üzerinde etkilidir ve kestirim boyunca hataların sürekli karelerinin alınması, büyük

hatalar açısından performans sonuçlarını toplamda oldukça etkiler. Buna rağmen sonuçlar yüksek frekanslı büyük hatalara karşı MAE kadar duyarlı değildir. Örneğin, birbirine oldukça yakın fakat birinin anlık yüksek bir kestirim hatasına sahip olduğu iki kestirim verisinde, MAE'ye göre sonuçların oldukça farklı olması beklenirken MSE için performans değerleri yüksek ama birbirine daha yakın olacaktır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (d_i - f_i)^2 \quad (4.48)$$

RMSE (Root Mean Squared Error) veya RMSD (Root Mean Squared Deviation), performans değerlendirmelerinde sıklıkla kullanılmaktadır. Hatanın veri ile aynı birim cinsinden ifade edilebilmesi karekökünün alınmasıyla olanaklı olmuştur.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - f_i)^2} = \sqrt{MSE} \quad (4.49)$$

Korelasyon katsayısı, iki sürekli değişken arasındaki lineer ilişki düzeyinin değişkenlerin biriminden bağımsız bir göstergesidir ve boyutsuz büyüklüktür. Pearson çarpım moment korelasyon katsayısı olarak da isimlendirilmektedir ve dağılım normal olduğunda kullanılmaktadır. $-1 \leq \rho \leq +1$ arasında değerler alır ve $+1$ 'e yaklaştıkça pozitif lineer korelasyon, -1 'e yaklaştıkça ise negatif lineer korelasyon düzeyini ifade eder. ρ 'nun sıfıra yakın olması ise korelasyonun olmadığı anlamına gelir. Sosyal bilimler açısından genellikle $+0.8 \leq \rho \leq +1$ ve $-1 \leq \rho \leq -0.8$ güçlü ve $0 \leq \rho \leq +0.5$ ve $-0.5 \leq \rho \leq 0$ zayıf korelasyon olarak değerlendirilmektedir fakat veri türüne göre değerlendirme ölçütleri farklılık göstermektedir [94]. Çalışmada kullandığımız kestirim ve gerçek sürekli değişkenlerinin nonlinear olduğu göz önünde bulundurulmalıdır.

$$\rho = \frac{n \sum_{i=1}^n d_i f_i - \left(\sum_{i=1}^n d_i \right) \left(\sum_{i=1}^n f_i \right)}{\sqrt{n \left(\sum_{i=1}^n d_i^2 \right) - \left(\sum_{i=1}^n d_i \right)^2} \sqrt{n \left(\sum_{i=1}^n f_i^2 \right) - \left(\sum_{i=1}^n f_i \right)^2}} \quad (4.50)$$

Belirlilik katsayısı, bir değişkendeki varyansın diğer değişken açısından düzeyini vermektedir. $0 \leq R^2 \leq +1$ arasında değerler almakta ve değişkenler arasındaki lineer ilişki düzeyini ifade etmektedir. Belirlilik katsayısı, bilginin ne kadarının regresyon çizgisi tarafından ifade edilebildiğinin oransal bir göstergesidir. Örneğin, $R^2=0.75$ ise bir değişkendeki toplam varyasyonun %75'inin iki değişken arasındaki lineer ilişki çerçevesinde açıklanabileceği anlamına gelmektedir [94].

$$R^2 = \left(\frac{n \sum_{i=1}^n d_i f_i - \left(\sum_{i=1}^n d_i \right) \left(\sum_{i=1}^n f_i \right)}{\sqrt{n \left(\sum_{i=1}^n d_i^2 \right) - \left(\sum_{i=1}^n d_i \right)^2} \sqrt{n \left(\sum_{i=1}^n f_i^2 \right) - \left(\sum_{i=1}^n f_i \right)^2}} \right)^2 = \rho^2 \quad (4.51)$$

Çalışma kapsamında performans ölçümleri çerçevesinde değerlendirmeye alınmadığı halde, araştırmacıların yararlanabilmeleri açısından literatür araştırmasında karşılaşılan diğer performans kriterleri;

- MFE (The Mean Forecast Error), ME (Mean Error), BIAS

$$MFE = \frac{1}{n} \sum_{i=1}^n d_i - f_i \quad (4.52)$$

- MAPE (The Mean Absolute Percentage Error)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{d_i - f_i}{d_i} \right| \times 100 \quad (4.53)$$

- MPE (The Mean Percentage Error)

$$MPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{d_i - f_i}{d_i} \right) \times 100 \quad (4.54)$$

- SMSE (The Signed Mean Squared Error)

$$SMSE = \frac{1}{n} \sum_{i=1}^n \frac{(d_i - f_i)^3}{|d_i - f_i|} \quad (4.55)$$

- NMSE (The Normalized Mean Squared Error)

$$NMSE = \frac{1}{\sigma^2 n} \sum_{i=1}^n (d_i - f_i)^2 = \frac{MSE}{\sigma^2} \quad (4.56)$$

- NRMSE (The Normalized Root Mean Squared Error)

$$NRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - f_i)^2}}{f_{max} - f_{min}} \quad (4.57)$$

- DS (Directional Symmetry)

$$DS = \frac{100}{n} \sum_{i=1}^n s_i; \quad s_i = \begin{cases} 1 & (d_i - d_{i-1})(f_i - f_{i-1}) \geq 0 \\ 0 & \text{diğer} \end{cases} \quad (4.58)$$

- The Theil's U-statistics

$$U = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - f_i)^2}}{\sqrt{\frac{1}{n} \sum_{i=1}^n d_i^2} \sqrt{\frac{1}{n} \sum_{i=1}^n f_i^2}} \quad (4.59)$$

5. ZAMAN SERİLERİNDE ANALİZ

Bölüm beş yapılan kestirim sonuçlarını içermektedir. 2009 Ocak ile 2013 Aralık arasını kapsayan ilk beş senelik veri setleri ağların eğitimi amacıyla kullanılmış ve 2014 Ocak ile 2015 Haziran arasını kapsayan son bir yıl altı aylık veri ise eğitilen ağlarla kestirilmeye çalışılmıştır. Elde edilen en iyi sonuçlar, Şekil 5.33 - 5.53'de gerçek verilerle kestirim sonuçlarını içermektedir.

Tablo 5.1'de elliot, sigmoid, lineer ve hiperbolik tanjant aktivasyon fonksiyonlarının her birinde MAE, MSE, RMSE, $\rho(r)$ ve R^2 hata ve ilişki kriterlerinin en iyi eğitim aşaması ve kestirim sonuçları verilmektedir. En iyi sonuçlar MAE, MSE ve RMSE hata kriterlerinde minimum, -1 ve 1 arası değerler alabilen ρ ilişki kriterinde ve 0 ile 1 arası değerler alabilen R^2 ilişki kriterinde ise maksimum değerler şeklindedir. Tablo 5.2 ve 5.3'de ise söz konusu en iyi sonuçların sırasıyla girdi veri seti içeriği ve ilgili ağa ait gizli katman hücre sayısı verilmektedir. Tablo 5.1, 5.2 ve 5.3'de ilgili ağın ilgili değerlendirme kriterine göre elde edildiği en iyi değerler koyu ve bütün ağlar içinde ilgili hata kriterinin en iyi değerleri ise altı çizgili biçimde yazılmıştır. Köşeli parantez içerisine alınan tablo değerleri ise en iyi eğitimin aynı zamanda en iyi kestirim sonucunu verdiği ağları göstermek için kullanılmıştır ve yalnızca eğitim bölümü üzerinde işaretlenmiştir.

Tablo 5.1 incelediğinde, MSE ile RMSE ve $\rho(r)$ ile R^2 'nin birbirine paralel sonuçlar ürettiği görülmektedir. Çünkü bu değerlendirme kriterleri birbirlerinin ifadesi şeklinde yazılabilmektedir. Tablo 5.1'den çıkan bir diğer sonuç ise eğitim düzeyi en iyi ağın genellikle en iyi kestirim sonucunu ürettiğidir. MLP ağlarında ise en iyi eğitim düzeyi hiçbir zaman en iyi kestirim sonucunu vermemiştir ve en iyi eğitim her zaman hiperbolik tanjant aktivasyon fonksiyonu kullanılan ağlarda gerçekleşmiştir. Test sonuçları en başarılı olan ağlar ise yine eğitim düzeyi yeterli olan ağlardır. Fakat meçhul bir değeri kestirim söz konusu olduğundan, en iyi eğitim düzeyine sahip olmasa bile bu ağların sistemi daha iyi modelleyebilmesi olanaklıdır. Tablo 5.2 incelendiğinde, MLP ağlarının diğer ağlara göre eğitim aşamasında daha karmaşık girdilere ihtiyaç duyduğu görülmektedir. Bunun temel sebebi statik bir ağ olması ve girdi ile çıktı arasında daha iyi haritalama gerçekleştirebilmek için ilişki kurabileceği ağırlıklara ihtiyaç duymasıdır. Test aşamasında t-1..3;ay giriş veri setinin daha başarılı kestirim sonuçları ürettiği görülmesi ise kestirim sonucu ile yakın zamanlı girdi setinin daha yüksek korelasyona sahip olması anlamına gelir. MLP ağları statik olduğundan öğrenme ve kestirim, girdi veri seti üzerinden doğrudan gerçekleşmektedir ve zaman serisi üzerindeki ilişkiler doğrudan girdi içeriğinden elde edilmeye çalışılmaktadır. Çalışmada, lineer aktivasyon fonksiyonuna göre çok sayıdaki ağ ağırlıkları da düşünüldüğünde girdi ve çıktı arasında tanjant hiperbolik aktivasyon fonksiyonunu ve bu

fonksiyona çok benzeyen elliot fonksiyonunun daha iyi nonlinear ilişkiler kurabildiği görülmektedir. Bu açıdan değerlendirildiğinde MLP ağları nonlinear zaman serisini hiperbolik tanjant aktivasyon fonksiyonunda en iyi öğrenmiş ve yakın denilebilecek eğitim düzeylerinde elliot aktivasyon fonksiyonlu ağlarda ise daha iyi kestirim yapabilmektedir. Tablo 5.3'e bakıldığında lineer aktivasyon fonksiyonunda giriş ile birlikte beklenen sınır öğrenme düzeyine ulaşabilmek için az sayıda gizli katman hücre sayısının yeterli olduğu ve arttırılmasının öğrenmeye etki etmediği görülmektedir. Bu durumda girdi veri setinden elde edilen anlamlı bileşenin ağ ağırlıklarına dağıtıldığı söylenebilir.

TDNN ağlarında zaman gecikmesi, giriş katmanında bir pencere oluşturur ve aynı girişler giriş katmanında daha fazla ağırlık oluşturarak temsil edilebilirler. TDNN ağlarındaki FIR filtreleme etkisiyle yüksek frekans bileşenleri elimine olmakta ve böylelikle elde edilen daha öngörülebilir bir zaman serisi girdisi üzerinden ana hatlarıyla bir kestirim yapılabilmesi mümkün olmaktadır. İki ve üç gecikmeli ağ modellerinin, bir gecikmeli ağ modeline göre çoğunlukla girdi ile çıktı arasında daha iyi haritalama yapabilmek için daha fazla gizli katman hücre sayısı ile birlikte modele dahil olan ağırlıklara ve daha fazla girdi bilgisine ihtiyaç duyduğu görülmektedir. Yine öğrenme ve kestirim başarısı elliot aktivasyon fonksiyonuna doğru değişmiştir. Zaman serisini bir işaret olarak düşündüğümüzde aşırı filtrelenmesiyle birlikte detay bilgi kaybı olduğu sonucuna ulaşılabilir.

Elman ağlarında özellikle lineer aktivasyon fonksiyonunda eğitim sürekli gerçekleşmemiştir ve diğer ağlara nazaran eğitimleri için daha uzun süreye ihtiyaç olmaktadır. Bunun temel sebebi geribeslemenin gizli katmanda olması ve öğrenme esnasında ayarlanmaya çalışılan ağırlıklar üzerinden bir geribesleme sağlanmasıdır. Bu açıdan düşünüldüğünde daha zorlu bir eğitim sürecinden geçmesi nedeniyle girdi veri setindeki kestirim için uygun bileşenleri daha iyi çıkarması ve daha kararlı kestirim ağırlıkları elde edilmesi beklenebilir. En iyi öğrenme diğer ağlardan farklı olarak sigmoid aktivasyon fonksiyonunda gerçekleşmiştir ve öğrenmenin gerçekleştiği diğer aktivasyon fonksiyonlarına yakın bir düzeydedir. Tablo 5.21 ve 5.23'de eğitimin sürekli gerçekleşmediğinin bir örneği yer almaktadır.

Bütün ağlar içerisinde en iyi eğitim ve test sonuçları bir geribeslemeli NARX ağlarında elde edilmiştir. NARX ağlarının genellikle lineer aktivasyon fonksiyonunda daha başarılı olduğu Tablo 5.1'den görülmektedir. Bunun temel sebebi kestirim gününün, veri setini takip eden gün olması yani kısa süreli tahmin yapılıyor olunmasıdır. NARX ağları modeli gereği kestirim sonuçlarını üretmekte ve sonra geribesleme ile düzenlemektedir. Bu geribesleme neticesinde kestirim sonuçları önceki çıktılara yeni bir ağırlıkla bağ kurmakta ve bu ağırlıklar ağın kalibrasyonunda önemli bir rol

üstlenmektedir.

Tablo 5.1’e göre, hata kriterleri açısından genel olarak aynı ağ yapılarında farklı aktivasyon fonksiyonlarında yakın düzeyde öğrenme sağlanabilmektedir. Ağ değerlendirilmelerinde; gizli katman hücre sayısı farklı fakat ağ yapısı, aktivasyon fonksiyonu ve girdi veri seti aynı olan ağ modellerinin farklı hata kriteri açısından farklı en iyi ağ olarak değerlendirebildiği görülmektedir. Farklı kriterlere göre farklı sayıda gizli katman hücresine sahip ağlar daha başarılı olarak değerlendirilebilmektedir.

Tablo 5.1. En iyi sonuçları veren ağlar için MAE, MSE, RMSE, $\rho(r)$ ve R^2 değerleri

		Eğitim					Test				
		MAE	MSE	RMSE	ρ	R^2	MAE	MSE	RMSE	ρ	R^2
MLP	Elliot	0.247523	0.103457	0.321647	0.857729	0.735699	3.309202	17.092968	4.134364	0.697593	0.486635
	Sigmoid	0.200865	0.072161	0.268629	0.903132	0.815647	3.306550	17.213425	4.148906	0.695173	0.483265
	Lineer	0.345386	0.192698	0.438974	0.712539	0.507711	3.374884	17.703198	4.207517	0.683575	0.467274
	Tanh	0.199803	0.071461	0.267322	0.904123	0.817438	3.336191	17.230563	4.150971	0.694926	0.482922
Bir geçkennel	Elliot	[0.180995]	[0.047536]	[0.218027]	[0.975403]	[0.951411]	1.745757	4.108012	2.026823	0.976070	0.952712
	Sigmoid	0.175930	0.047448	0.217825	[0.972324]	[0.945413]	1.670198	4.057712	2.014376	0.973888	0.948457
	Lineer	[0.160810]	[0.039498]	[0.198742]	[0.988325]	[0.976786]	1.577556	3.484240	1.866612	0.987580	0.975314
	Tanh	0.175638	0.044892	0.211876	[0.968214]	[0.937438]	1.619595	4.134385	2.033319	0.970130	0.941152
TDNN İki geçkennel	Elliot	[0.259757]	[0.113351]	[0.336677]	[0.853362]	[0.728226]	2.547277	10.383652	3.222367	0.847129	0.717627
	Sigmoid	0.260821	0.123406	0.351292	[0.834264]	[0.695996]	2.533272	10.376411	3.221244	0.834974	0.697181
	Lineer	[0.273435]	[0.124966]	[0.353505]	[0.838379]	[0.702879]	2.611379	11.088406	3.329926	0.828666	0.686687
	Tanh	[0.265809]	[0.125359]	[0.354060]	[0.837843]	[0.701980]	2.416811	10.524199	3.244102	0.837131	0.700788
Üç geçkennel	Elliot	[0.285622]	[0.124378]	[0.352672]	[0.863078]	[0.744903]	2.703046	11.454133	3.384396	0.854576	0.730300
	Sigmoid	[0.274508]	[0.131284]	[0.362332]	[0.816402]	[0.666512]	2.631518	11.831491	3.439694	0.804336	0.646956
	Lineer	0.305980	[0.147524]	[0.384088]	[0.796696]	[0.634724]	2.911237	13.079485	3.616557	0.786620	0.618771
	Tanh	[0.297592]	[0.142834]	[0.377934]	[0.803824]	[0.646133]	2.839252	12.704702	3.564366	0.796984	0.635183
ELMAN Bir geribeslemeli	Elliot	0.195266	[0.056932]	[0.238604]	[0.957539]	[0.916880]	1.832852	5.151424	2.269675	0.955522	0.913022
	Sigmoid	[0.194074]	[0.056008]	[0.236661]	[0.964408]	[0.930082]	1.858317	4.900787	2.213772	0.962088	0.925613
	Lineer	0.197409	[0.059178]	[0.243265]	[0.949517]	[0.901582]	1.999360	5.625664	2.371848	0.944621	0.892308
	Tanh	0.182674	[0.056883]	[0.238501]	0.956508	0.914907	1.899428	5.099703	2.258252	0.954862	0.911761
Bir geribeslemeli	Elliot	0.174903	[0.037844]	[0.194536]	[0.992592]	[0.985238]	1.573808	3.161664	1.778107	0.992599	0.985252
	Sigmoid	0.153139	[0.033182]	[0.182160]	[0.991476]	[0.983024]	1.447183	2.854739	1.689597	0.992124	0.984310
	Lineer	[0.135331]	[0.025045]	[0.158258]	[1.000000]	[1.000000]	1.294386	2.199231	1.482981	1.000000	1.000000
	Tanh	[0.166511]	[0.033324]	[0.182550]	[0.990307]	[0.980707]	1.502149	2.708633	1.645792	0.991665	0.983399
NARX İki geribeslemeli	Elliot	[0.241997]	[0.095612]	[0.309213]	[0.802473]	[0.766109]	2.290682	8.464498	2.909381	0.869476	0.755988
	Sigmoid	[0.260891]	[0.104368]	[0.323060]	[0.892088]	[0.795821]	2.494032	9.114425	3.019011	0.886358	0.785630
	Lineer	[0.231549]	[0.090339]	[0.300565]	[0.891716]	[0.795157]	2.254493	8.201095	2.863755	0.882898	0.779508
	Tanh	[0.252196]	[0.110381]	[0.332237]	[0.850720]	[0.723724]	2.440236	10.321197	3.212662	0.836684	0.700040
Üç geribeslemeli	Elliot	[0.270364]	[0.131509]	[0.362642]	[0.815581]	[0.665172]	2.609694	12.191423	3.491622	0.798468	0.637551
	Sigmoid	[0.290626]	[0.137784]	[0.371193]	[0.807607]	[0.652229]	2.764365	12.237186	3.498169	0.796859	0.634984
	Lineer	[0.271709]	[0.130739]	[0.361578]	[0.825164]	[0.680895]	2.614251	11.718346	3.423207	0.815584	0.665177
	Tanh	[0.286973]	0.153155	0.391350	0.783563	0.613970	2.776074	13.646855	3.694165	0.775285	0.601066

* MAE, MSE ve RMSE için minimum değerler

** $\rho(r)$ ve R^2 için maksimum değerler


Tablo 5.2. En iyi sonuçları veren ağlar için girdi türleri

		Eğitim					Test				
		MAE	MSE	RMSE	ρ	R^2	MAE	MSE	RMSE	ρ	R^2
MLP	Elliot	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1;t-2	t-1..3;ay	t-1..3;ay	t-1..3;ay	t-1..3;ay
	Sigmoid	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1;t-2	t-1..3;ay	t-1..3;ay	t-1..3;ay	t-1..3;ay
	Lineer	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5	t-1..4	t-1..4	t-1..4	t-1..4
	Tanh	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1;t-2	t-1;t-2;ay	t-1;t-2;ay	t-1;t-2;ay	t-1;t-2;ay
Bir gecekönlü	Elliot	[t-1]	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
	Sigmoid	t-1;t-2	t-1..5	t-1..5	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
	Lineer	[t-1;t-2]	[t-1]	[t-1]	[t-1]	[t-1]	t-1;t-2	t-1	t-1	t-1	t-1
	Tanh	t-1..4	t-1..4	t-1..4	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
İki gecekönlü	Elliot	[t-1;t-2;ay]	[t-1;t-2;ay]	[t-1;t-2;ay]	[t-1..5]	[t-1..5]	t-1;t-2;ay	t-1;t-2;ay	t-1;t-2;ay	t-1..5	t-1..5
	Sigmoid	t-1	t-1..5	t-1..5	[t-1..4]	[t-1..4]	t-1..5	t-1..4	t-1..4	t-1..4	t-1..4
	Lineer	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2
	Tanh	[t-1..4]	[t-1..4]	[t-1..4]	[t-1..4]	[t-1..4]	t-1..4	t-1..4	t-1..4	t-1..4	t-1..4
Üç gecekönlü	Elliot	[t-1..3]	[t-1..5;ay]	[t-1..5;ay]	[t-1..5;ay]	[t-1..5;ay]	t-1..3	t-1..5;ay	t-1..5;ay	t-1..5;ay	t-1..5;ay
	Sigmoid	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2
	Lineer	t-1..5	[t-1]	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1
	Tanh	[t-1..5]	[t-1..3]	[t-1..3]	[t-1..5]	[t-1..5]	t-1..5	t-1..3	t-1..3	t-1..5	t-1..5
ELMAN Bir gecekönlü	Elliot	t-1..3;ay	[t-1]	[t-1]	[t-1..4]	[t-1..4]	t-1	t-1	t-1	t-1..4	t-1..4
	Sigmoid	[t-1..3]	[t-1..3]	[t-1..3]	[t-1;t-2]	[t-1;t-2]	t-1..3	t-1..3	t-1..3	t-1;t-2	t-1;t-2
	Lineer	t-1..3	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
	Tanh	t-1	[t-1;t-2]	[t-1;t-2]	t-1	t-1	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2
Bir gecekönlü	Elliot	t-1;ay	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
	Sigmoid	t-1..3	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
	Lineer	[t-1;ay]	[t-1;ay]	[t-1;ay]	[t-1]	[t-1]	t-1;t-2;ay	t-1;ay	t-1;ay	t-1	t-1
	Tanh	[t-1]	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
NARX İki gecekönlü	Elliot	[t-1..3]	[t-1..3]	[t-1..3]	[t-1..3]	[t-1..3]	t-1..3	t-1..3	t-1..3	t-1..3	t-1..3
	Sigmoid	[t-1]	[t-1..4]	[t-1..4]	[t-1..4]	[t-1..4]	t-1	t-1..4	t-1..4	t-1..4	t-1..4
	Lineer	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2	t-1;t-2
	Tanh	[t-1]	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
Üç gecekönlü	Elliot	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	[t-1;t-2]	t-1;t-2	t-1;t-2	t-1;t-2	t-1..4	t-1..4
	Sigmoid	[t-1..4]	[t-1..4]	[t-1..4]	[t-1..4]	[t-1..4]	t-1..4	t-1..4	t-1..4	t-1..4	t-1..4
	Lineer	[t-1]	[t-1]	[t-1]	[t-1]	[t-1]	t-1	t-1	t-1	t-1	t-1
	Tanh	[t-1..5]	t-1..4	t-1..4	t-1..4	t-1..4	t-1..5	t-1..4;ay	t-1..4;ay	t-1..4;ay	t-1..4;ay


Tablo 5.3. En iyi sonuçları veren ağlar için gizli katman hücre sayıları

		Eğitim					Test				
		MAE	MSE	RMSE	ρ	R^2	MAE	MSE	RMSE	ρ	R^2
MLP	Elliot	17	4	4	4	4	17	4	4	4	4
	Sigmoid	15	3	3	3	3	15	3	3	3	3
	Lineer	12	19	19	19	19	12	19	19	19	19
	Tanh	12	3	3	3	3	12	3	3	3	3
	Bir gecikmeli										
	Elliot	[19]	[3]	[3]	[3]	[3]	19	3	3	3	3
	Sigmoid	10	46	46	[12]	[12]	10	46	46	12	12
	Lineer	[41]	[5]	[5]	[49]	[49]	41	5	5	49	49
	Üç gecikmeli										
	Elliot	[38]	[38]	[38]	[50]	[50]	38	38	38	50	50
	Sigmoid	9	45	45	[45]	[45]	9	45	45	45	45
	Lineer	[20]	[55]	[55]	[55]	[55]	20	55	55	55	55
	TDNN										
	Elliot	[32]	[26]	[26]	[26]	[26]	32	26	26	26	26
	Sigmoid	[22]	[22]	[22]	[22]	[22]	22	22	22	22	22
	Lineer	58	[58]	[58]	[58]	[58]	58	58	58	58	58
	ELMAN										
	Elliot	10	[10]	[10]	[5]	[5]	10	10	10	5	5
	Sigmoid	[29]	[8]	[8]	[6]	[6]	29	8	8	6	6
	Lineer	3	[3]	[3]	[3]	[3]	3	3	3	3	3
	Bir geribeslemeli										
	Elliot	44	[54]	[54]	[54]	[54]	44	54	54	54	54
	Sigmoid	15	[15]	[15]	[15]	[15]	15	15	15	15	15
	Lineer	[21]	[8]	[8]	[26]	[26]	21	8	8	26	26
	Bir geribeslemeli										
	Elliot	[29]	[29]	[29]	[29]	[29]	29	29	29	29	29
	Sigmoid	[56]	[37]	[37]	[37]	[37]	56	37	37	37	37
	Lineer	[4]	[4]	[4]	[4]	[4]	4	4	4	4	4
	NARX										
	Elliot	[25]	[25]	[25]	[3]	[3]	25	25	25	3	3
	Sigmoid	[56]	[56]	[56]	[38]	[38]	56	56	56	38	38
	Lineer	[30]	[30]	[30]	[30]	[30]	30	30	30	30	30
	Üç geribeslemeli										
	Elliot	[24]	35	35	31	31	24	31	31	31	31
	Sigmoid	[17]	[17]	[17]	[17]	[17]	17	17	17	17	17
	Lineer	[30]	[30]	[30]	[30]	[30]	30	30	30	30	30
	Tanh	[24]	35	35	31	31	24	31	31	31	31


△ MLP




Şekil 5.2. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.1. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.3. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri



Şekil 5.4. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.5. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.6. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri

△ TDNN

▷ Bir zaman gecikmeli ağ




Şekil 5.7. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.8. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri


▷ İki zaman gecikmeli ağ




Şekil 5.10. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri



Şekil 5.9. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.11. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.12. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri


▷ Üç zaman gecikmeli ağ




Şekil 5.14. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.13. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.15. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri



Şekil 5.16. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.17. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.18. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri

- △ SRN (Elman Ağı)
- ▷ Bir geribeslemeli ağ




Şekil 5.19. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.20. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri

△ NARX


▷ Bir geribeslemeli ağ




Şekil 5.22. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri



Şekil 5.21. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.23. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.24. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri


▷ İki geribeslemeli ağ




Şekil 5.26. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri



Şekil 5.25. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.27. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.28. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri


▷ Üç geribeslemeli ağ




Şekil 5.30. Sigmoid aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri



Şekil 5.29. Elliot aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.31. Lineer aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri




Şekil 5.32. Hiperbolik tanjant aktivasyon fonksiyonunda (a) Eğitim verileri, (b) Test verileri için gizli katman hücre sayısına göre hata değişimleri


△ En iyi kestirim sonuçları




Şekil 5.33. t-1..3;ay veri setinin, 4 gizli hücreli ve Elliot aktivasyon fonksiyonlu MLP ağlarında kestirim sonuçları




Şekil 5.34. t-1;t-2 veri setinin, 15 gizli hücreli ve sigmoid aktivasyon fonksiyonlu MLP ağlarında kestirim sonuçları




Şekil 5.35. t-1;t-2 veri setinin, 41 gizli hücreli ve lineer aktivasyon fonksiyonlu bir gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.36. $t-1$ veri setinin, 5 gizli hücreli ve lineer aktivasyon fonksiyonlu bir gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.37. $t-1$ veri setinin, 49 gizli hücreli ve lineer aktivasyon fonksiyonlu bir gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.38. $t-1..5$ veri setinin, 50 gizli hücreli ve Elliot aktivasyon fonksiyonlu iki gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.39. t-1..4 veri setinin, 45 gizli hücreli ve sigmoid aktivasyon fonksiyonlu iki gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.40. t-1..4 veri setinin, 41 gizli hücreli ve hiperbolik tanjant aktivasyon fonksiyonlu iki gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.41. t-1..5;ay veri setinin, 26 gizli hücreli ve elliot aktivasyon fonksiyonlu üç gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.42. t-1;t-2 veri setinin, 22 gizli hücreli ve sigmoid aktivasyon fonksiyonlu üç gecikmeli TDNN ağlarında kestirim sonuçları




Şekil 5.43. t-1 veri setinin, 10 gizli hücreli ve Elliot aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları




Şekil 5.44. t-1..3 veri setinin, 8 gizli hücreli ve sigmoid aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları




Şekil 5.45. $t-1;t-2$ veri setinin, 6 gizli hücreli ve sigmoid aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları




Şekil 5.46. $t-1;t-2$ veri setinin, 16 gizli hücreli ve hiperbolik tanjant aktivasyon fonksiyonlu bir geribeslemeli ELMAN ağlarında kestirim sonuçları




Şekil 5.47. $t-1;t-2;ay$ veri setinin, 21 gizli hücreli ve lineer aktivasyon fonksiyonlu bir geribeslemeli NARX ağlarında kestirim sonuçları




Şekil 5.48. $t-1$ ay veri setinin, 8 gizli hücreli ve lineer aktivasyon fonksiyonlu bir geribeslemeli NARX ağlarında kestirim sonuçları




Şekil 5.49. $t-1$ veri setinin, 26 gizli hücreli ve lineer aktivasyon fonksiyonlu bir geribeslemeli NARX ağlarında kestirim sonuçları




Şekil 5.50. $t-1..4$ veri setinin, 37 gizli hücreli ve sigmoid aktivasyon fonksiyonlu iki geribeslemeli NARX ağlarında kestirim sonuçları



Şekil 5.51. $t-1;t-2$ veri setinin, 4 gizli hücreli ve lineer aktivasyon fonksiyonlu iki geribeslemeli NARX ağlarında kestirim sonuçları



Şekil 5.52. $t-1;t-2$ veri setinin, 56 gizli hücreli ve Elliot aktivasyon fonksiyonlu üç geribeslemeli NARX ağlarında kestirim sonuçları



Şekil 5.53. $t-1$ veri setinin, 30 gizli hücreli ve lineer aktivasyon fonksiyonlu üç geribeslemeli NARX ağlarında kestirim sonuçları

6. TARTIŞMA VE ÖNERİLER

Çalışmada uçuşa elverişlilik meteorolojik hadiseler açısından değerlendirilmiş ve bu maksatla aday pilotların eğitimleri için uygun meteorolojik koşullar üzerinde bir araştırma yapılmıştır. ICAO gereklilikleri de göz önünde bulundurularak istatistiksel bir çalışma gerçekleştirilmiş ve bununla beraber zaman serileri de oluşturularak kestirim çalışması yapılmıştır.

Çalışmanın istatistiksel basamağında yer alan uçuşa elverişlilik verileri 2009 - 2014 yılları arasındaki METAR tablolarından elde edilmiştir. Bu nedenle değişen iklim koşulları açısından düşünüldüğünde çalışmanın güncellenmesi ve tekrar edilmesi mümkündür. Ayrıca çalışma alanı olarak Hasan Polatkan Havaalanı seçilmiş ve bununla sınırlı tutulmuştur. Eğitim faaliyeti gösteren diğer uçuş eğitim organizasyonları açısından diğer pistler için çalışmanın yinelenmesi mümkündür.

Çalışmanın diğer basamağı ise kısa süreli kestirimlerin yapay sinir ağları metodlarıyla gerçekleştirilmesinden oluşmaktadır. Geçmiş beş güne kadar ki uçuşa elverişli saat bilgisini içeren ve kestirimin gerçekleştirildiği ay bilgisini içerebilen 10 farklı veri setinden izleyen güne ilişkin durum tahmin edilmektedir. Bu maksatla veri setleri; 4 farklı aktivasyon fonksiyonu içeren 3 - 60 arasında gizli katman hücrelerine sahip, statik ve geri dönüşümlü olmak üzere 4 farklı ağ yapısı üzerinde, üç zamana kadar gecikme ve üç geribesleme içerebilen toplam 8 yapı ile modellenmeye çalışılmış ve toplamda 18,240 yapay sinir ağında çalışma gerçekleştirilmiştir. Kestirim yapılacak süre arttıkça hava durumunun yakın zamanlı durumlara göre gerçek veri ile kestirim arasındaki korelasyonunun düşmesi beklenir. Fakat uzun vadeli kestirimleri içeren çalışmalar da yapılabilir. Çalışmanın girdi katmanı veri setleri dalgacık dönüşümü yöntemleriyle zenginleştirilerek çalışma tekrar edilebilir; bulanık sinir ağları, radyal tabanlı sinir ağları gibi yapay sinir ağları yöntemleriyle veya ARMA, NARMA ve Kalman filtreleme gibi farklı metodlarla zaman serilerinde kestirimler yapılarak kıyaslanabilir. ROC analizi ile çalışma sonuçları farklı bir yaklaşımla tekrar değerlendirilebilir ve çalışma tekrar edilerek genişletilebilir.

KAYNAKÇA

- [1] Gleick, J. (2014(1987)). *KAOS: Yeni bir bilim ortaya çıkarken*. İstanbul: Melisa Matbaacılık.
- [2] Karaçay, T. (2004). Determinizm ve kaos. *Mantık, Matematik ve Felsefe Ulusal Sempozyumu^{II}*.
- [3] Esen, O. (2013). Meteorolojide ölçüm belirsizliği. *Kalkınmada Anahtar Verimlilik*, (290).
- [4] Danforth, C. A. and Lewiston, M. (2001). Why the weather is unpredictable, an experimental and theoretical study of the Lorenz equations. MSc Thesis. England: The Faculty of the Department of Mathematics and the Department of Physics Bates College.
- [5] Saperstein, A.M. (1986). Chaos and determinism: A paradigm. *IEEE AES Magazine*.
- [6] Devlet Hava Meydanları İşletmesi (2016). AIP.
<http://www.ssd.dhmi.gov.tr> (Erişim Tarihi: 04.01.2016).
- [7] Anadolu Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi (2016). LTBY Havaalanı.
<http://ecas.anadolu.edu.tr/havaalani> (Erişim Tarihi: 04.01.2016).
- [8] Samsun Ondokuz Mayıs Üniversitesi Tıp Fakültesi Havacılık Tıp Merkezi. (2014). *Organizasyon el kitabı: TR-AMC-003*. Samsun.
- [9] Kenaroğlu, Y. (2011). Hava araçlarının uçuşa elverişlilik sertifikasyonu. *Mühendis ve Makina Dergisi*, 52 (614).
- [10] Armutlu, K. (2009). *Tek piston motorlu pervaneli eğitim uçaklarında ağırlık ve motor gücünün yakıt tüketimi ve işletme giderlerine etkisi*. Doktora Tezi. Eskişehir: Anadolu Üniversitesi.
- [11] Hocaoglu, F.O., Oysal Y. and Kurban, M. (2009). Missing wind data forecasting with adaptive neuro-fuzzy inference system. *Neural Comput. Appl.*, 18 (3), 207–212.
- [12] Hocaoglu, F.O. and Kurban, M. (2007). The effect of missing wind speed data on wind power estimation, *IDEAL 2007: 8th International Conference of Intelligent Data Engineering And Automated Learning*, Berlin, Springer, 107–114.
- [13] Wen, R. and Wang, H. (2010). Forecasting flight time based on BP neural network. *Control and Decision Conference (CCDC)*, China, 4232–4236.
- [14] Hu, M.J.C. and Halbert, E.R. (1964). An adaptive data processing system for weather forecasting. *Journal of Applied Meteorology*, 3 (5), 513–523.
- [15] Luk, K.C., Ball, J.E. and Sharma, A. (2001). An application of artificial neural networks for rainfall forecasting. *Mathematical and Computer Modelling* 33 (6–7), 683–693.
- [16] Ramirez, M.C.V., Velho, H.F.C. and Ferreira, N.J. (2005). Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *Journal of Hydrology* 301 (1-4), 146–162.

- [17] Charaniya, N.A. and Dudul, S.V. (2011). Committee of artificial neural networks for monthly rainfall prediction using wavelet transform. *IEEE International Conference of Business, Engineering and Industrial Applications (ICBEIA2011)*, 125–129.
- [18] Kaynar, O. ve Taştan, S. (2009). Zaman serisi analizinde MLP yapay sinir ağları ve ARIMA modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* (33), 161–172.
- [19] Rani, B.K. and Govardhan, A. (2013). Rainfall prediction using data mining techniques - A survey. *ICAIT - 2013*, 23–30.
- [20] Öztopal, A. ve Şen, Z. (2009). Kısa vadeli yağış modellemesi için yapay sinir ağları yaklaşımı. *İTÜDERGİSİ/d*, 8 (1), 83–94.
- [21] Öztopal, A. (2007). *Uydu ve yer kaynaklı meteorolojik değişkenlere kısa vadeli yağış modellemesi için yapay sinir ağı yaklaşımı*. Doktora Tezi. İstanbul: İstanbul Teknik Üniversitesi.
- [22] Abhishek, K. et al. (2012). A rainfall prediction model using artificial neural network. *IEEE Control and System Graduate Research Colloquium (ICSGRC 2012)*, 82–87.
- [23] Dubey, A. D. (2015). Artificial neural network models for rainfall prediction in Pondicherry. *International Journal of Computer Applications*, 120 (3), 30–35.
- [24] Kızılkaya, A.E. ve Gencer, C. (2007). Kaba küme yaklaşımı kullanılarak veri madenciliği problemlerinde sınıflandırma amaçlı yapılmış olan çalışmalar. *Kara Harp Okulu Savunma Bilimleri Dergisi*, 6, 17–31.
- [25] Çekik, R. ve Telçeken, S. (2014). EKG sinyallerinin kaba kümeler teorisi kullanılarak sınıflandırılması. *Anadolu University of Sciences & Technology - A: Applied Sciences & Engineering*, 15 (2), 125–135.
- [26] Li, K. and Liu, Y.L. (2005). A rough set based fuzzy neural network algorithm for weather prediction. *Machine Learning and Cybernetics*, 1888–1892.
- [27] Abraham, A., Steinberg, D. and Philip, N.S. (2001). Rainfall forecasting using soft computing models and multivariate adaptive regression splines. *IEEE SMC Transactions: Special*.
- [28] Saplıoğlu, K. ve Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1 (1), 14–21.
- [29] Shoba, G. and Shobha, G. (2014). Rainfall prediction using data mining techniques: A Survey. *International Journal of Engineering and Computer Science*, 3 (5), 6206–6211.
- [30] Zhang, M., Fulcher J. and Scofield, R.A. (1997). Rainfall estimation using artificial neural network group. *Neurocomputing*, 16 (2), 97–115.
- [31] El-Shafie, A. and et. al. (2012). Dynamic versus static neural network model for rainfall forecasting at Klang River Basin, Malaysia. *Hydrology and Earth System Sciences*, 16 (4), 1151–1169.
- [32] Partal, T. (2007). *Türkiye yağış miktarlarının yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini*. Doktora Tezi. İstanbul: İstanbul Teknik Üniversitesi.

- [33] Partal, T., Kahya E. ve Cıgızoğlu, K. (2008). Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. *İTÜDERGİSİ/d*, 7 (3), 73–85.
- [34] Hayati, M. and Mohebi, Z. (2007). Temperature forecasting based on neural network approach. *World Applied Sciences Journal*, 2 (6), pp. 613–620.
- [35] Dombaycı, Ö.A. and Gölcü, M. (2009). Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey. *Renewable Energy*, 34 (4), 1158–1161.
- [36] Banik, S., Anwer, M. and Khan, A.F.M.K. (2010). Soft computing models to predict daily temperature of Dhaka. *Computer and Information Technology (ICCIT2010)*, 75–80.
- [37] Atasoy, V.E. (2015). *Bir uçuş eğitim organizasyonunun üretkenliğine etki eden faktörlerin incelenmesi*.Yükse Lisans Tezi. Eskişehir: Anadolu Üniversitesi.
- [38] Askerî Meteoroloji Şube Müdürlüğü (2009). Havacılık meteorolojisi. Ankara: Devlet Meteoroloji İşleri Genel Müdürlüğü.
- [39] Maloof, M.A. (2002). On machine learning, ROC analysis, and statistical tests of significance. *Proceeding of 16th International Conference on Pattern Recognition*. 2, 204–207.
- [40] Tokan, F., Turker, N. and Yıldırım, T. (2006). Determination of the neural network performances in the medical prognosis by ROC analysis. *14th IEEE Conference on Signal Processing and Communications Applications*, 1–4.
- [41] Fabbian, D., Dear, R. and Lellyett, S. (2007). Application of artificial neural network forecasts to predict fog at Canberra International Airport. *Weather and Forecasting* 22 (2), 372–381.
- [42] Costa, S.B. and ark. (2006). Fog forecast for The International Airport of Maceió, Brazil using artificial neural network. *Environment and Electrical Engineering (EEEIC)*, 24 (28), 1741–1750.
- [43] Aktaş, C. ve Erkuş, O. (2009). Lojistik regresyon analizi ile Eskişehir’in sis kestiriminin incelenmesi. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, (16), 47–59.
- [44] Colabone, R.O. and ark. (2015). Application of artificial neural networks for fog forecast. *Journal of Aerospace Technology Management*, 7(2), 240–246.
- [45] Sureerattanan, S. and ark. (2006). The optimal multi-layer structure of backpropagation networks. *Croatia: World Scientific, Engineering Academy, and Society (WSEAS)*, 108–113.
- [46] Atik, K., Deniz, E. ve Yıldız, E. (2007). Meteorolojik verilerin yapay sinir ağları ile modellenmesi. *KSÜ Fen ve Mühendislik Dergisi*, 10 (1), 148–152.
- [47] Altay, A., Özkan, Ö. and Kayakutlu, G. (2014). Prediction of aircraft failure times using artificial neural networks and genetic algorithms. *Journal of Aircraft*, 51 (1), 47–53.

- [48] Wardah, T. and et. al. (2011). Statistical verification of numerical weather prediction models for quantitative precipitation forecast. *IEEE Colloquium on Humanities, Science and 76 Engineering (CHUSER)*, 88–92.
- [49] Akbilgiç, O. ve Keskintürk T. (2008). Yapay sinir ağları ve çoklu regresyon analizinin karşılaştırılması. *Yönetim*, 19 (60), 74–83.
- [50] Watters, C.S. and Leahy, P. (2011). Comparison of linear, Kalman filter and neural network downscaling of wind speeds from numerical weather prediction. *10th International Conference on Environment and Electrical Engineering (EEEIC2011)*, 1–4
- [51] Paras S.M. (2012). A simple weather forecasting model using mathematical regression. *Indian Research Journal of Extension Education (Special Issue)*, 1, 161–168.
- [52] Weiguo, X. (2010). The weather prediction method based on artificial immune system. *International Forum on Information Technology and Applications (IFITA2010)*, 2, 386–389.
- [53] Kumar, D.N. and Sathish, T. (2004). Forecasting hydrologic time series using artificial neural networks. *Applied Soft Computing*, 7 (2), 585-592
- [54] International Civil Aviation Organization. (2007). *Annex 3 to the convention on International Civil Aviation, Meteorological Service for International Air Navigation*.
- [55] Keel, B.M. and et. al. (2000). Aviation weather information requirements study. NASA/CR-2000/210228.
- [56] Uslu, S., ed. (2014). Havacılık ve hava trafik kontrol. Eskişehir: Aktüel Ofset.
- [57] Sivil Havacılık Genel Müdürlüğü (2016). Türk hava sahasında hava kurallarının uygulanmasına ilişkin usul ve esaslar talimatı. <http://web.shgm.gov.tr/documents/sivilhavacilik/files/mevzuat/sektorel/taslaklar/SHT-HK.pdf> (Erişim tarihi: 14.10.2016).
- [58] Pilotaj bölümü eğitim el kitabı (2013). Eskişehir: Anadolu Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi.
- [59] Devlet Hava Meydanları İşletmesi Seyrüsefer Dairesi Başkanlığı. (2004). *Meteoroloji ders kitabı*. Ankara.
- [60] Cessna a Textron Company. (1998). *Cessna 172S pilot operating manual*. USA.
- [61] EADS Socata. (1988). *TB20 pilot's information manual*. France.
- [62] Gültepe, I., ed. (2007). Fog and boundary layer clouds: Introduction. I. Gultepe (Ed) *Fog and boundary layer clouds: Fog visibility and forecasting* in (p. 1115-111). Germany: Birkhäuser
- [63] World Meteorological Organization. (1975). *International cloud atlas*.
- [64] Bruyn, V. (2012). *Cloud classification (image)*.
- [65] National Meteorological Library and Archive. Met Office. (2011). *Fact sheet clouds*.
- [66] Theseven seas. (2009). *Approximate length of daylight*, 77 (image).

- [67] Ham, F.M. and Kostanic, I. (2003). *Principles of neurocomputing for science & engineering*. McGrawHill Education. Çin: McGraw-Hill Education.
- [68] Öztemel, E. (2012). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- [69] Haykin, S. (1998). *Neural networks: A comprehensive foundation* (2nd edition). Upper Saddle River, NJ, USA: Prentice Hall PTR.
- [70] Freeman, J.A. and Skapura, D.M. (1991). *Neural networks algorithms, applications, and programming techniques*. Addison-Wesley Publishing Company.
- [71] Elmas, Ç. (2010). *Yapay zeka uygulamaları*. Ankara: Seçkin Yayıncılık.
- [72] Kalogirio, S.A. (2000). Applications of artificial neural-networks for energy systems. *Applied Energy*, 67, 17–35.
- [73] Elliott, D.L. (1993). A better activation function for artificial neural networks. ISR Technical Report TR 93-8.
- [74] Sibi, P., Jones, S.A and Siddarth, P. (2013). Analysis of different activation functions using back propagation neural networks. *Journal of Theoretical and Applied Information Technology*, 47 (83), 1264–1268.
- [75] Kalogirio, S.A. and Bojic, M. (2000). Artificial neural networks for the prediction of the energy consumption of a passive solar building. *Energy*, 25 (5), 479–491.
- [76] Kůrková, V. (1992). Kolmogorov's Theorem and Multilayer Neural Networks. *Neural Netw.*, 5 (3), 501–506.
- [77] Shamsuddin, S.M. and et. al. (2009). Study of cost functions in Three Term Backpropagation for classification problems. *2009 World Congress on Nature Biologically Inspired Computing (NaBIC)*, 564–570.
- [78] Yavuz, S. ve Deveci M. (2013). İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167–187.
- [79] Golik, P., Doetsch, P. and Ney, H. (2013). Cross-entropy vs.squared error training: a theoretical and experimental comparison. *INTERSPEECH.2013*, ISCA, 1756–1760.
- [80] Hastie, T.J., Tibshirani, R.J. and Friedman, J.H. (2009). *The elements of statistical learning: data mining, inference, and prediction*. New York: Springer.
- [81] Goodfellow, I., Bengio, Y. and Courville, A. (2016). *Deep learning (adaptive computation and machine learning series)*. USA: The MIT Press.
- [82] Amaral, T. (2013). Using Different Cost Functions to Train Deep Networks with Supervision. Tech. rep. Instituto de Engenharia Biomédica (INEB).
- [83] Amaral, T. and et. al. (2013). Using different cost functions to train stacked auto-encoders. *IEEE MICAI (Special Sessions)*, 114–120.
- [84] Hanson, S.J. and Burr, D.J. (1987). Minkowski-r back-propagation: Learning in connectionist models with non-euclidian error signals. *Neural Information Processing Systems NIPS'87*. USA: MIT Press, 348–357.

- [85] Du, K. and Swamy, M.N.S. (2013). *Neural Networks and Statistical Learning*. Springer Publishing Company, Incorporated.
- [86] Hagan, M. T. and Menhaj, M.B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5 (6), 989–993.
- [87] Gavin, H. (2016). The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems.
<http://people.duke.edu/~hpgavin/ce281/lm.pdf>. (Eriřim tarihi: 10.12.2016).
- [88] Wikipedia (2016a). LevenbergMarquardt algorithm.
https://en.wikipedia.org/wiki/Levenberg%E2%80%93Marquardt_algorithm. (Eriřim tarihi: 10.12.2016).
- [89] Yu, H. and Wilamowski B.M. (2011). LevenbergMarquardt Training. B. Wilamowski and J. David Irwin (Eds.). *The industrial electronics handbook series:intelligent systems (2nd edition)*. (p. 12-1). USA: CRC Press.
- [90] Lahmieri, S. (2011). A Comparative study of backpropagation algorithms in financial prediction. *International Journal of Computer Science, Engineering and Applications (IJCSEA)*, 1 (4).
- [91] Ross, S.M. (2012). *Olasılık ve İstatistięe Giriř: Mühendisler ve Fenciler için* (4.baskı). Türkiye: Nobel Akademik Yayıncılık Eğitim ve Danışmanlık Tic. Ltd. Şti.
- [92] Adhikari, R. and Agrawal, R.K. (2013). *An Introductory Study on Time Series Modeling and Forecasting*. Germany LAP Lambert Academic Publishing.
- [93] Field, A. (2009). *Discovering Statistics using SPSS (and sex and drugs and rock n roll)* (3rd edition). England: SAGE Publications Ltd.
- [94] MathBits (2016). Correlation Coefficient.
<https://mathbits.com/MathBits/TISection/Statistics2/correlation.htm> (Eriřim tarihi: 10.12.2016).
- [95] Wikipedia (2016b). Mean squared error.
https://en.wikipedia.org/wiki/Mean_squared_error (Eriřim tarihi: 10.12.2016).
- [96] Wikipedia (2016c). Root mean square deviation.
https://en.wikipedia.org/wiki/Root-mean-square_deviation (Eriřim tarihi: 10.12.2016).
- [97] Cao, L. J. and Tay, F.E.H. (2003). Support Vector Machine with Adaptive Parameters in Financial Time Series Forecasting. *Trans. Neur. Netw.*, 14 (6), 1506–1518.

EKLER

EK-1 Meydan İhbarları

Tropik Dönen Fırtına	: Kod 4677; 19 nolu hadise Kod 4678; FC
Oraj	: Kod 4677; 17, 95, 96, 97, 98 ve 99 nolu hadiseler Kod 4678; TS ve Kombinezonları
Dolu	: Kod 4677; 87, 88, 89, 90, 93 ve 94 nolu hadiseler Kod 4678; GR, GS ve Kombinezonları
Kar	: Kod 4677; 68, 69, 70, 71, 72, 73, 74, 75, 77, 83, 84, 85 ve 86 nolu hadiseler Kod 4678; SN ve Kombinezonları
Donan Yağış	: Kod 4677; 56, 57, 66 ve 67 nolu hadiseler Kod 4678; FZDZ, FZRA
Kırağı, Sert Kırağı	:
Kum Fırtınası, Toz Fırtınası	: Kod 4677; 30, 31, 32, 33, 34 ve 35 nolu hadiseler Kod 4678; SS, DS
Yükselen Toz, Kum	: Kod 4677; 07 nolu hadise Kod 4678; BLDU, BLSA
Savrulan Kar	: Kod 4677; 38 ve 39 nolu hadiseler Kod 4678; BLSN
Squall	: Kod 4677; 18 nolu hadise Kod 4678; SQ
Kuvvetli Rüzgâr ve Hamle	: Ortalama rüzgâr hızı ≥ 20 kt ise : Hamle ≥ 30 kt ise

Kaynak: [38/]

EK-2 SIGMET Mesajları

Tablo 2.1. Ses Altı Hız Seyir Seviyeleri Mesajları

Oraj	
Münferit Oraj	: OBSC TS
Gizli Oraj	: EMBD TS
Şiddetli (sık tekrarlayan) Oraj	: FRQ TS
Kararsızlık Hattı Orajı	: SQL TS
Dolu ile Birlikte Münferit Oraj	: OBSC TSGR
Dolu ile Birlikte Gizli Oraj	: EMBD TSGR
Dolu ile Birlikte Şiddetli Oraj	: FRQ TSGR
Dolu İle Birlikte Kararsızlık Hattı Orajı	: SQL TSGR
Tropikal Siklon	
10dk ortalama yer rüzgârının hızı 34 kt veya daha fazla ve tropikal siklon	: TC
Türbülans	
Şiddetli Türbülans	: SEV TURB
Buzlanma	
Şiddetli Buzlanma	: SEV ICE
Donan Yağmura Bağlı Buzlanma	: SEV ICE (FZRA)
Dağ Dalgaları	
Şiddetli Dağ Dalgası	: SEV MTW
Toz Fırtınası	
Kuvvetli Toz Fırtınası	: HVY DS
Kum Fırtınası	
Kuvvetli Kum Fırtınası	: HVY SS
Volkanik Kül	
Volkanik Kül	: VA

Kaynak: [38]

Tablo 2.2. Ses Üstü Hız Seyir Seviyeleri Mesajları

Türbülans	
Orta Şiddette Türbülans	: MOD TURB
Şiddetli Türbülans	: SEV TURB
Kümülonimbüs Bulutları	
Tek Başına Kümülonimbüs Bulutu	: ISOL CB
Yer Yer Görülen Kümülonimbüs Bulutları	: OCNL CB
Yoğun Kümülonimbüs Bulutları	: FRQ CB
Dolu	
Dolu	: GR
Volkanik Kül	
Volkanik Kül	: VA

Kaynak: [38]

EK-3 AIRMET Mesajları

Tablo 3.1. Ses Üstü Hız Seyir Seviyeleri Mesajları

Yer Rüzgârının Hızı		
Yer rüzgârının ortalama hızı ≥ 30 kt	:	SFC WSPD
Düşük Görüş Mesafesi		
Rüyet $\leq 5,000$ m	:	SFC VIS
Alçak Bulut		
Yüksekliği $\leq 1,500$ ft BKN/OVC bulutları	:	BKN/OVC CLD
Cumulonimbus (Cb) Bulutları		
Münferit	:	ISOL CB
Yer yer	:	OCNL CB
Sık sık	:	FRQ CB
Towering Cumulus (TCU) Bulutları		
Münferit	:	ISOL TCU
Yer yer	:	OCNL TCU
Sık sık	:	FRQ TCU
Oraj		
Dolu olmaksızın münferit oraj	:	ISOL TS
Dolu olmaksızın yer yer görülen oraj	:	OCNL TS
Dolu ile birlikte münferit oraj	:	ISOL TSGR
Dolu ile birlikte yer yer görülen oraj	:	OCNL TSGR
Dağ Engeli		
Dağın görülmesine engel teşkil eden hadise	:	MT OBSC
Türbülans		
Orta Şiddette Türbülans (Konvektif bulutlar içindeki türbülans hariç)	:	MOD TURB
Buzlanma		
Orta Şiddette Buzlanma (Konvektif bulutlar içindeki buzlanma hariç)	:	MOD ICE
Dağ Dalgası		
Orta Şiddette Dağ Dalgası	:	MOD MTW

Kaynak: [38]

EK-4 GAMET Mesajları

Tablo 4.1. Birinci Mesaj Bölümü(SECN I)

Rüzgâr	: ≥ 30 kt ortalama yer rüzgârı ve etki alanı
Görüş Mesafesi	: $\leq 5,000$ m yer seviyesi görüş mesafesi ve etki alanı
SIGWX - Önemli Hava Olayları	: Oraj Tropikal siklon Squall hattı Dolu Donan yağış(yağmur ve çisenti) Yağış türü hadiseler ve onların kombinezonları Kum fırtınası Toz fırtınası Kar savrulması Sis ve kombinezonları Diğer görüş engelleyici hadiseler Orta veya şiddetli dağ dalgası
Dağ ve dağların görülmesini engelleyen durumun mevcûdiyeti	
Bulutluluk durumu	
Orta şiddetli buzlanma (MOD ICE) ve şiddetli buzlanma (SEV ICE)	
Orta şiddetli türbülans (MOD TURB) ve şiddetli türbülans (SEV TURB)	

Kaynak: [38/

Tablo 4.2. İkinci Mesaj Bölümü(SECN II)

Basınç merkezleri ve cephesel sistemler	: Basınç merkezleri, merkezlerin değerleri, cephesel sistemler, hareket hızları ve yönleri, kuvvetlenme durumları
Tahmin edilen yüksek seviye rüzgârları ve sıcakları	: 1000, 2000, 3000, 5000, 7000, 10000 ve 15,000 ft'te tahmin edilen rüzgârın yönü, hızı ve sıcaklıkları
Bulut taban yüksekliği $\geq 1,500$ ft üzerindeki bulutlar	: Kapalılıkları BKN veya OVC olan bulutların kapalılık, cins, taban ve tepe yükseklikleri
0° C İzoterm yüksekliği	: 15,000 ft'in altında 0° C izoterm yüksekliği
Tahmin edilen en düşük QNH değeri	
Deniz yüzey sıcaklığı ve denizin durumu	: Deniz yüzey sıcaklığı ve denizin hali (dalga yüksekliği), büyük göllerdeki sıcaklık ve dalga yüksekliği v.s.
Volkanik aktivite	: Olayın kısa tanımı, volkanik faaliyetin yoğunluk seviyesi, volkanik kül bulutlarının durumu, kül bulutlarının hareket yönü ve yüksekliği

Kaynak: [38]

EK-5 Meteorolojik Hadiseler ve Limit Değerleri

IC, FU, DU, SA, HZ, BCFG	: Rüyeyet $\leq 5,000$ m
BR	: Rüyeyet 1000m $\sim 5,000$ m
FG, FZFG, SS, DS	: Rüyeyet $\leq 1,000$ m
BLSN, BLSA, BLDU, PO	: Rüyeyet $\leq 8,000$ m
+SN	: Rüyeyet $\leq 2,000$ m
FG	: Sıcaklık $> 0^{\circ}$ C
FZFG	: Sıcaklık $< 0^{\circ}$ C
FZFG	: Sıcaklık $> 5.4^{\circ}$ C ise rapor edilmez.
$\pm$ FZDZ, $\pm$ FZRA	: -12° C $<$ sıcaklık $< 5.4^{\circ}$ C
SN, PL, GS (TS ve SH ile kullanımları dâhil)	: Sıcaklık $< 6.5^{\circ}$ C
$\pm$ RA, $\pm$ DZ, $\pm$ RADZ, $\pm$ DZRA	: Sıcaklık $> -3.0^{\circ}$ C
$\pm$ RASN, $\pm$ SNRA, $\pm$ DZSN,	: -5° C $<$ sıcaklık $< 6.5^{\circ}$ C
$\pm$ SNDZ (SH dâhil)	
IC	: Sıcaklık $< -10^{\circ}$ C
FG	: İşba - sıcaklık $< 2^{\circ}$ C
SS, DS	: Rüzgâr hızı > 27 kt
DRSN, DRSA, DRDU, BLSN, BLSA, BLDU	: Rüzgâr hızı > 10 kt

Kaynak: [38]

EK-6 Uçuşa Elverişli Saatlerin Yıllara ve Aylara Göre Dağılımları

Tablo 6.1. Uçuşa elverişli saat dağılımı (günlük en az bir saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	118	108	85	52	102	120	98
Şubat	88	81	149	54	134	245	125
Mart	113	231	208	229	164	186	188
Nisan	253	294	163	257	247	271	247
Mayıs	320	350	210	224	333	281	286
Haziran	389	293	330	440	351	300	350
Temmuz	418	436	451	464	400	452	437
Ağustos	419	429	417	425	439	386	419
Eylül	300	324	335	368	359	239	321
Ekim	281	151	263	261	260	204	237
Kasım	186	264	211	132	217	150	193
Aralık	120	95	144	114	133	76	114
Toplam	3002	3054	2964	3020	3139	2910	3015

Tablo 6.2. Uçuşa elverişli saat dağılımı (günlük en az iki saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	116	107	85	50	101	117	96
Şubat	85	78	147	53	134	242	123
Mart	111	228	206	226	160	183	186
Nisan	251	292	160	256	247	271	246
Mayıs	320	347	206	223	333	280	285
Haziran	389	293	330	440	350	297	350
Temmuz	418	436	451	464	399	452	437
Ağustos	419	429	416	425	439	386	419
Eylül	299	324	334	368	359	239	320
Ekim	281	148	263	261	259	202	236
Kasım	184	264	211	131	216	149	192
Aralık	118	94	142	114	133	74	113
Toplam	2989	3038	2949	3010	3130	2892	3001

Tablo 6.3. Uçuşa elverişli saat dağılımı (günlük en az üç saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	110	96	83	48	95	115	91
Şubat	81	70	145	42	132	242	119
Mart	105	222	204	224	158	177	181
Nisan	251	290	154	256	245	269	244
Mayıs	320	347	204	221	329	276	283
Haziran	389	291	326	440	350	295	348
Temmuz	418	436	451	464	397	452	436
Ağustos	419	429	416	425	439	386	419
Eylül	299	324	334	368	359	235	320
Ekim	281	142	261	257	259	198	233
Kasım	182	264	209	129	214	147	191
Aralık	114	90	140	112	131	72	110
Toplam	2966	2999	2925	2985	3108	2864	2974

Tablo 6.4. Uçuşa elverişli saat dağılımı (günlük en az dört saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	110	90	80	48	95	109	89
Şubat	69	64	145	39	129	239	114
Mart	102	222	204	218	158	171	179
Nisan	248	290	151	253	242	260	240
Mayıs	317	347	201	218	326	270	280
Haziran	389	288	326	440	347	292	347
Temmuz	418	436	451	464	394	452	436
Ağustos	419	429	416	425	439	386	419
Eylül	290	324	327	365	359	231	316
Ekim	275	139	257	254	256	195	229
Kasım	179	264	209	126	214	141	189
Aralık	114	84	128	109	125	63	104
Toplam	2927	2975	2894	2958	3084	2808	2941

Tablo 6.5. Uçuşa elverişli saat dağılımı (günlük en az beş saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	106	78	80	48	87	101	83
Şubat	65	52	141	27	129	234	108
Mart	94	218	204	218	158	171	177
Nisan	244	290	139	249	238	260	236
Mayıs	309	347	185	206	318	261	271
Haziran	389	284	326	440	343	292	346
Temmuz	418	436	451	464	390	452	435
Ağustos	419	425	416	425	439	382	417
Eylül	290	320	327	365	359	231	315
Ekim	267	127	253	242	256	191	223
Kasım	170	264	204	118	214	141	185
Aralık	110	76	124	105	125	55	99
Toplam	2878	2915	2849	2906	3055	2771	2896

Tablo 6.6. Uçuşa elverişli saat dağılımı (günlük en az altı saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	106	73	80	38	71	101	78
Şubat	55	47	126	7	119	234	98
Mart	84	218	188	213	158	161	170
Nisan	239	284	129	244	233	255	230
Mayıs	304	347	170	196	308	256	263
Haziran	389	284	311	440	343	292	343
Temmuz	418	436	451	464	390	447	434
Ağustos	414	425	416	425	434	382	416
Eylül	285	315	322	365	354	211	309
Ekim	256	122	253	227	251	186	216
Kasım	170	254	194	113	209	136	179
Aralık	90	61	119	100	110	45	88
Toplam	2808	2864	2759	2831	2980	2706	2824

Tablo 6.7. Uçuşa elverişli saat dağılımı (günlük en az yedi saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	106	73	80	38	71	101	78
Şubat	55	47	126	7	119	234	98
Mart	84	218	188	213	158	161	170
Nisan	239	284	129	244	233	255	230
Mayıs	304	347	170	196	308	256	263
Haziran	389	284	311	440	343	292	343
Temmuz	418	436	451	464	390	447	434
Ağustos	414	425	416	425	434	382	416
Eylül	285	315	322	365	354	211	309
Ekim	256	122	253	227	251	186	216
Kasım	170	254	194	113	209	136	179
Aralık	90	61	119	100	110	45	88
Toplam	2717	2785	2660	2758	2884	2633	2739

Tablo 6.8. Uçuşa elverişli saat dağılımı (günlük en az sekiz saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	94	47	73	38	38	75	61
Şubat	55	28	113	0	107	214	86
Mart	70	205	175	199	145	126	153
Nisan	206	277	97	223	215	216	205
Mayıs	290	327	149	153	288	237	241
Haziran	363	234	280	433	310	271	315
Temmuz	398	430	444	464	383	440	426
Ağustos	407	417	416	419	434	376	411
Eylül	278	301	316	365	348	204	302
Ekim	230	102	219	206	245	173	196
Kasım	144	247	181	79	203	136	165
Aralık	57	49	86	81	77	31	64
Toplam	2591	2663	2548	2659	2792	2498	2625

Tablo 6.9. Uçuşa elverişli saat dağılımı (günlük en az dokuz saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	94	39	41	30	30	51	48
Şubat	39	28	105	0	75	206	75
Mart	62	197	167	191	136	110	144
Nisan	189	269	89	198	215	207	194
Mayıs	290	311	132	129	280	229	228
Haziran	355	218	272	433	310	263	308
Temmuz	398	422	444	464	375	432	422
Ağustos	390	417	408	411	426	352	401
Eylül	278	260	316	365	348	180	291
Ekim	222	86	211	190	229	165	184
Kasım	120	231	124	71	179	128	142
Aralık	41	49	70	73	69	31	56
Toplam	2477	2525	2379	2555	2672	2354	2493

Tablo 6.10. Uçuşa elverişli saat dağılımı (günlük en az on saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	85	21	41	21	21	42	39
Şubat	30	10	78	0	66	197	63
Mart	62	197	158	181	118	110	138
Nisan	180	212	89	162	197	207	175
Mayıs	262	311	123	111	280	229	219
Haziran	337	200	263	406	301	245	292
Temmuz	398	413	444	464	375	432	421
Ağustos	390	417	408	402	426	352	399
Eylül	269	241	306	347	321	180	277
Ekim	195	68	202	172	220	156	169
Kasım	84	213	88	44	161	119	118
Aralık	32	22	43	64	33	31	38
Toplam	2323	2324	2243	2374	2519	2300	2347

Tablo 6.11. Uçuşa elverişli saat dağılımı (günlük en az on bir saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	55	11	11	11	11	22	20
Şubat	0	0	48	0	36	176	43
Mart	52	187	158	151	108	100	126
Nisan	149	140	89	142	197	197	152
Mayıs	232	300	103	81	270	199	198
Haziran	317	180	233	396	271	245	274
Temmuz	368	403	444	464	375	432	414
Ağustos	390	407	408	402	426	332	394
Eylül	259	221	306	337	301	160	264
Ekim	185	48	182	132	170	146	144
Kasım	44	99	78	34	99	89	74
Aralık	22	22	33	44	33	11	28
Toplam	2072	2017	2093	2194	2297	2109	2130

Tablo 6.12. Uçuşa elverişli saat dağılımı (günlük en az on iki saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	48	0	36	132	36
Mart	52	176	125	140	75	78	108
Nisan	149	71	67	109	175	175	124
Mayıs	221	278	81	70	270	188	185
Haziran	295	125	233	396	249	245	257
Temmuz	368	403	422	431	353	421	400
Ağustos	378	396	408	402	415	321	387
Eylül	248	221	306	326	289	116	251
Ekim	152	48	138	110	137	124	118
Kasım	0	0	12	12	0	12	6
Aralık	0	0	0	0	0	0	0
Toplam	1863	1717	1840	1996	1999	1812	1871

Tablo 6.13. Uçuşa elverişli saat dağılımı (günlük en az on üç saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	40	52	65	104	27	66	59
Nisan	113	59	55	97	175	127	104
Mayıs	209	266	57	58	270	176	173
Haziran	283	100	233	396	237	233	247
Temmuz	344	354	386	407	353	421	378
Ağustos	354	396	408	365	415	297	372
Eylül	199	135	306	266	265	92	211
Ekim	104	0	78	26	65	52	54
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	1646	1362	1588	1719	1807	1464	1597

Tablo 6.14. Uçuşa elverişli saat dağılımı (günlük en az on dört saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	14	0	0	0	14	14	7
Nisan	100	59	29	58	175	127	91
Mayıs	209	239	57	58	270	163	166
Haziran	283	61	233	396	224	220	236
Temmuz	318	315	373	407	340	408	360
Ağustos	341	356	382	325	415	297	353
Eylül	56	70	98	84	70	14	65
Ekim	0	0	0	0	0	0	0
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	1321	1099	1172	1328	1508	1243	1278

Tablo 6.15. Uçuşa elverişli saat dağılımı (günlük en az on beş saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	0	0	0	0	0	0	0
Nisan	30	45	15	30	105	15	40
Mayıs	195	225	15	30	256	135	143
Haziran	269	32	191	396	224	192	217
Temmuz	262	300	345	393	326	408	339
Ağustos	285	300	240	255	345	255	280
Eylül	0	0	0	0	0	0	0
Ekim	0	0	0	0	0	0	0
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	1040	902	806	1104	1256	1005	1019

Tablo 6.16. Uçuşa elverişli saat dağılımı (günlük en az on altı saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	0	0	0	0	0	0	0
Nisan	0	0	0	0	0	0	0
Mayıs	0	0	0	0	16	0	3
Haziran	208	32	176	336	224	192	195
Temmuz	96	240	240	288	176	288	221
Ağustos	0	0	0	0	0	0	0
Eylül	0	0	0	0	0	0	0
Ekim	0	0	0	0	0	0	0
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	304	272	416	624	416	480	419

EK-7 Uçuşa Elverişli Günlerin Yıllara ve Aylara Göre Dağılımları

Tablo 7.1. Uçuşa elverişli gün dağılımı (günlük en az bir saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	17	21	11	9	18	20	16
Şubat	17	19	20	15	17	27	19
Mart	18	26	23	26	20	26	23
Nisan	27	30	25	27	23	28	27
Mayıs	28	30	29	29	30	29	29
Haziran	30	30	30	30	30	27	30
Temmuz	31	31	31	31	31	31	31
Ağustos	31	31	30	31	31	30	31
Eylül	28	30	29	30	30	26	29
Ekim	30	23	27	31	26	24	27
Kasım	24	27	25	19	24	18	23
Aralık	20	17	23	15	19	15	18
Toplam	301	315	303	293	299	301	302

Tablo 7.2. Uçuşa elverişli gün dağılımı (günlük en az iki saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	15	20	11	7	17	17	15
Şubat	15	16	18	14	17	24	17
Mart	16	23	21	23	16	23	20
Nisan	25	28	22	26	23	28	25
Mayıs	28	27	25	28	30	28	28
Haziran	30	30	30	30	29	24	29
Temmuz	31	31	31	31	30	31	31
Ağustos	31	31	29	31	31	30	31
Eylül	27	30	28	30	30	26	29
Ekim	30	21	27	31	25	22	26
Kasım	23	27	25	18	23	17	22
Aralık	18	16	21	15	19	13	17
Toplam	289	300	288	284	290	283	289

Tablo 7.3. Uçuşa elverişli gün dağılımı (günlük en az üç saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	12	15	10	6	14	16	12
Şubat	13	12	17	9	16	24	15
Mart	13	20	20	22	15	20	18
Nisan	25	27	19	26	22	27	24
Mayıs	28	27	24	27	28	26	27
Haziran	30	29	28	30	29	23	28
Temmuz	31	31	31	31	29	31	31
Ağustos	31	31	29	31	31	30	31
Eylül	27	30	28	30	30	24	28
Ekim	30	18	26	29	25	20	25
Kasım	22	27	24	17	22	16	21
Aralık	16	14	20	14	18	12	16
Toplam	278	281	276	272	279	269	276

Tablo 7.4. Uçuşa elverişli gün dağılımı (günlük en az dört saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	12	13	9	6	14	14	11
Şubat	9	10	17	8	15	23	14
Mart	12	20	20	20	15	18	18
Nisan	24	27	18	25	21	24	23
Mayıs	27	27	23	26	27	24	26
Haziran	30	28	28	30	28	22	28
Temmuz	31	31	31	31	28	31	31
Ağustos	31	31	29	31	31	30	31
Eylül	24	30	26	29	30	23	27
Ekim	28	17	25	28	24	19	24
Kasım	21	27	24	16	22	14	21
Aralık	16	12	16	13	16	9	14
Toplam	265	273	266	263	271	251	265

Tablo 7.5. Uçuşa elverişli gün dağılımı (günlük en az beş saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	11	10	9	6	12	12	10
Şubat	8	7	16	5	15	22	12
Mart	10	19	20	20	15	18	17
Nisan	23	27	15	24	20	24	22
Mayıs	25	27	19	23	25	22	24
Haziran	30	27	28	30	27	22	27
Temmuz	31	31	31	31	27	31	30
Ağustos	31	30	29	31	31	29	30
Eylül	24	29	26	29	30	23	27
Ekim	26	14	24	25	24	18	22
Kasım	19	27	23	14	22	14	20
Aralık	15	10	15	12	16	7	13
Toplam	253	258	255	250	264	242	254

Tablo 7.6. Uçuşa elverişli gün dağılımı (günlük en az altı saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	11	9	9	4	9	12	9
Şubat	6	6	13	1	13	22	10
Mart	8	19	17	19	15	16	16
Nisan	22	26	13	23	19	23	21
Mayıs	24	27	16	21	23	21	22
Haziran	30	27	25	30	27	22	27
Temmuz	31	31	31	31	27	30	30
Ağustos	30	30	29	31	30	29	30
Eylül	23	28	25	29	29	19	26
Ekim	24	13	24	22	23	17	21
Kasım	19	25	21	13	21	13	19
Aralık	11	7	14	11	13	5	10
Toplam	239	248	237	235	249	229	240

Tablo 7.7. Uçuşa elverişli gün dağılımı (günlük en az yedi saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	9	7	8	4	7	10	8
Şubat	6	4	12	1	11	20	9
Mart	7	18	16	18	14	15	15
Nisan	20	26	10	22	16	20	19
Mayıs	24	25	15	15	22	19	20
Haziran	28	26	21	30	25	22	25
Temmuz	29	30	31	31	27	30	30
Ağustos	30	30	29	30	30	28	30
Eylül	23	27	24	29	28	19	25
Ekim	22	12	23	22	22	16	20
Kasım	17	25	20	12	20	13	18
Aralık	9	5	12	9	11	5	9
Toplam	224	235	221	223	233	217	226

Tablo 7.8. Uçuşa elverişli gün dağılımı (günlük en az sekiz saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	9	5	8	4	4	8	6
Şubat	6	3	11	0	11	19	8
Mart	6	17	15	17	13	11	13
Nisan	17	25	8	20	16	17	17
Mayıs	22	24	13	14	20	18	19
Haziran	26	20	20	29	22	19	23
Temmuz	28	30	30	31	26	29	29
Ağustos	29	29	29	30	30	28	29
Eylül	22	26	24	29	28	18	25
Ekim	20	10	19	19	22	15	18
Kasım	15	24	19	8	20	13	17
Aralık	6	5	9	8	8	3	7
Toplam	206	218	205	209	220	198	209

Tablo 7.9. Uçuşa elverişli gün dağılımı (günlük en az dokuz saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	9	4	4	3	3	5	5
Şubat	4	3	10	0	7	18	7
Mart	5	16	14	16	12	9	12
Nisan	15	24	7	17	16	16	16
Mayıs	22	22	11	11	19	17	17
Haziran	25	18	19	29	22	18	22
Temmuz	28	29	30	31	25	28	29
Ağustos	27	29	28	29	29	25	28
Eylül	22	21	24	29	28	15	23
Ekim	19	8	18	17	20	14	16
Kasım	12	22	12	7	17	12	14
Aralık	4	5	7	7	7	3	6
Toplam	192	201	184	196	205	180	193

Tablo 7.10. Uçuşa elverişli gün dağılımı (günlük en az on saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	8	2	4	2	2	4	4
Şubat	3	1	7	0	6	17	6
Mart	5	16	13	15	10	9	11
Nisan	14	18	7	13	14	16	14
Mayıs	19	22	10	9	19	17	16
Haziran	23	16	18	26	21	16	20
Temmuz	28	28	30	31	25	28	28
Ağustos	27	29	28	28	29	25	28
Eylül	21	19	23	27	25	15	22
Ekim	16	6	17	15	19	13	14
Kasım	8	20	8	4	15	11	11
Aralık	3	2	4	6	3	3	4
Toplam	175	179	169	176	188	174	177

Tablo 7.11. Uçuşa elverişli gün dağılımı (günlük en az on bir saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	5	1	1	1	1	2	2
Şubat	0	0	4	0	3	15	4
Mart	4	15	13	12	9	8	10
Nisan	11	11	7	11	14	15	12
Mayıs	16	21	8	6	18	14	14
Haziran	21	14	15	25	18	16	18
Temmuz	25	27	30	31	25	28	28
Ağustos	27	28	28	28	29	23	27
Eylül	20	17	23	26	23	13	20
Ekim	15	4	15	11	14	12	12
Kasım	4	9	7	3	9	8	7
Aralık	2	2	3	4	3	1	3
Toplam	150	149	154	158	166	155	155

Tablo 7.12. Uçuşa elverişli gün dağılımı (günlük en az on iki saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	4	0	3	11	3
Mart	4	14	10	11	6	6	9
Nisan	11	5	5	8	12	13	9
Mayıs	15	19	6	5	18	13	13
Haziran	19	9	15	25	16	16	17
Temmuz	25	27	28	28	23	27	26
Ağustos	26	27	28	28	28	22	27
Eylül	19	17	23	25	22	9	19
Ekim	12	4	11	9	11	10	10
Kasım	0	0	1	1	0	1	1
Aralık	0	0	0	0	0	0	0
Toplam	131	122	131	140	139	128	132

Tablo 7.13. Uçuşa elverişli gün dağılımı (günlük en az on üç saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	3	4	5	8	2	5	5
Nisan	8	4	4	7	12	9	7
Mayıs	14	18	4	4	18	12	12
Haziran	18	7	15	25	15	15	16
Temmuz	23	23	25	26	23	27	25
Ağustos	24	27	28	25	28	20	25
Eylül	15	10	23	20	20	7	16
Ekim	8	0	6	2	5	4	4
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	113	93	110	117	123	99	109

Tablo 7.14. Uçuşa elverişli gün dağılımı (günlük en az on dört saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	1	0	0	0	1	1	1
Nisan	7	4	2	4	12	9	6
Mayıs	14	16	4	4	18	11	11
Haziran	18	4	15	25	14	14	15
Temmuz	21	20	24	26	22	26	23
Ağustos	23	24	26	22	28	20	24
Eylül	4	5	7	6	5	1	5
Ekim	0	0	0	0	0	0	0
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	88	73	78	87	100	82	85

Tablo 7.15. Uçuşa elverişli gün dağılımı (günlük en az on beş saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	0	0	0	0	0	0	0
Nisan	2	3	1	2	7	1	3
Mayıs	13	15	1	2	17	9	10
Haziran	17	2	12	25	14	12	14
Temmuz	17	19	22	25	21	26	22
Ağustos	19	20	16	17	23	17	19
Eylül	0	0	0	0	0	0	0
Ekim	0	0	0	0	0	0	0
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	68	59	52	71	82	65	66

Tablo 7.16. Uçuşa elverişli gün dağılımı (günlük en az on altı saat)

	2009	2010	2011	2012	2013	2014	Ortalama
Ocak	0	0	0	0	0	0	0
Şubat	0	0	0	0	0	0	0
Mart	0	0	0	0	0	0	0
Nisan	0	0	0	0	0	0	0
Mayıs	0	0	0	0	1	0	0
Haziran	13	2	11	21	14	12	12
Temmuz	6	15	15	18	11	18	14
Ağustos	0	0	0	0	0	0	0
Eylül	0	0	0	0	0	0	0
Ekim	0	0	0	0	0	0	0
Kasım	0	0	0	0	0	0	0
Aralık	0	0	0	0	0	0	0
Toplam	19	17	26	39	26	30	26