



**UÇUŞA ELVERİŞLİLİĞİN ZAMAN
SERİLERİNDE KISA VADELİ KESTİRİM
İÇİN MODELLENMESİ**

Doktora Tezi

Ali TATLI

Eskişehir 2022

**UÇUŞA ELVERİŞLİLİĞİN ZAMAN SERİLERİNDE KISA VADELİ
KESTİRİM İÇİN MODELLENMESİ**

Ali TATLI

Doktora Tezi

Havacılık Elektrik ve Elektronik Anabilim Dalı

Danışman: Prof. Dr. Tahir Hikmet KARAKOÇ

(İkinci Danışman: Doç. Dr. Tansu FİLİK)

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ağustos 2022

Bu tez çalışması BAP Komisyonu tarafından kabul edilen 20DRP055 no.lu proje kapsamında desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Ali TATLI'nın UÇUŞA ELVERİŞLİLİĞİN ZAMAN SERİLERİNDE KISA VADELİ KESTİRİM İÇİN MODELLENMESİ başlıklı çalışması 01/08/2022 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Havacılık Elektrik ve Elektronik Anabilim dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye	: Doç. Dr. Işıl YAZAR	
Üye	: Doç Dr. Selçuk EKİCİ	
Üye	: Dr. Öğr. Üyesi Sinem KAHVECİOĞLU	
Üye	: Dr. Öğr. Üyesi Elif KORUYUCU	
Üye	: Dr. Öğr. Üyesi Alper DALKIRAN	

Prof. Dr. Murat TANIŞLI

Lisansüstü Eğitim Enstitüsü Müdürü

01/08/2022

DANIŞMAN ONAYI

Danışmanlığını yürüttüğüm Doktora öğrencisi Ali TATLI, UÇUŞA ELVERİŞLİLİĞİN ZAMAN SERİLERİNDE KISA VADELİ KESTİRİM İÇİN MODELLENMESİ başlıklı tez çalışmasını tamamlamıştır. Hazırlamış olduğu tez tarafımda incelenmiş ve öğrencinin tez savunma sınavına alınması bilimsel ve etik açıdan uygun görülmüştür.

Tez Danışmanı

Prof. Dr. Tahir Hikmet KARAKOÇ

ÖZET

UÇUŞA ELVERİŞLİLİĞİN ZAMAN SERİLERİNDE KISA VADELİ KESTİRİM İÇİN MODELLENMESİ

Ali TATLI

Havacılık Elektrik ve Elektronik Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ağustos 2022

Danışman: Prof. Dr. Tahir Hikmet KARAKOÇ

(İkinci Danışman: Doç. Dr. Tansu FİLİK)

Havacılık alanında meteorolojik hâdiseler oldukça önem arz eden fenomenlerdir. Meteorolojik hâdiseler neticesinde havacılık faaliyetleri zaman zaman aksamaktadır. Envanter ya da insan faktörleri gibi ikame edilememeleri ve kontrol altına alınamamaları yönüyle öncelikle göz önünde bulundurulmalıdırlar. Bu çalışmada, uçuş eğitim organizasyonları için meteorolojik hâdiselerin önemi Eskişehir Teknik Üniversitesi Pilotaj Bölümü (ESTÜ-P) örneği üzerinde incelenmektedir. Havacılık otoriteleri tarafından belirlenen düzenlemelerin öngördüğü resmi ölçütler ve eğitmen pilot tecrübelerine dayanan gayri resmi ölçütlerle on iki seneyi kapsayan meydan rutin hava raporlarından (METAR, Meteorological Aerodrome Reports) elde edilmiş uçuşa elverişlilik zaman serilerinde ayrıştırma ve derin öğrenme yöntemleri ile izleyen güne ilişkin tahmin modeli önerilmektedir. Ayrıca planlama faaliyetlerine katkı sağlaması ve uçuş eğitim organizasyonlarını inceleyen araştırmacılara kaynak oluşturması amacıyla 2009–2020 arasını kapsayan istatistikî uçuşa elverişlilik sonuçları ortaya konulmuştur.

Anahtar Sözcükler: Uçuşa Elverişlilik, LSTM, GRU, EMD, VMD.

ABSTRACT

SHORT-TERM PREDICTION MODEL OF AIRWORTHINESS IN TIME SERIES

Ali TATLI

Department of Avionics

Eskişehir Technical University, Institute of Graduate Programs, August 2022

Supervisor: Prof. Dr. Tahir Hikmet KARAKOÇ

(Co-Supervisor: Assoc. Prof. Dr. Tansu FİLİK)

Meteorological events are very important phenomena in aviation field. Aviation activities are interrupted from time to time as a result of meteorological events. They should be considered primarily as they cannot be substituted and controlled such as inventory or human factors. In this study, the importance of meteorological events for flight training organizations is examined on the case of Eskişehir Technical University Pilotage Department (ESTU-P). Airworthiness time series were obtained from meteorological aerodrome reports (METAR) covering a period of twelve years, using the official criteria in the regulations determined by the aviation authorities and the informal criteria based on the instructor pilot experiences. Prediction models for the next day are suggested by using decomposition and deep learning methods in time series. In addition, statistical airworthiness results for the period 2009-2020 have been presented in order to contribute to planning activities and provide resources for researchers who examine flight training organizations.

Keywords: Airworthiness, LSTM, GRU, EMD, VMD.

TEŞEKKÜR

Bütün gayret ve dikkatini sürdürülebilir havacılığa adanmış, bu alanda uluslararası önemli organizasyonlara ve çalışmalara imza atan duayen bir isimle çalışmaktan kıvanç duymaktayım. Tecrübelerinden ve bakış açısından sürekli istifade ettiğim kıymetli tez danışmanım Prof. Dr. Tahir Hikmet KARAKOÇ'a teşekkürlerimi sunarım.

Sinyal konusunda gerek dersleri gerek tavsiyeleriyle bakış açımın gelişmesinde rol oynayan kıymetli ikinci danışmanım Doç. Dr. Tansu FİLİK'e teşekkürlerimi sunarım.

Tezin gelişim sürecini titizlikle takip ederek yönlendiren ve şekillenmesinde katkılarını hiçbir zaman esirgemeyerek sürekli destek olan kıymetli tez izleme komitesi üyesi Doç. Dr. Işıl YAZAR'a teşekkürlerimi sunarım. Doktora sürecinde de beni yalnız bırakmayarak çalışmaları tez izleme komitesi üyesi olarak titizlikle takip eden ve yönlendiren kıymetli yüksek lisans tez danışmanım Dr. Öğr. Üyesi Sinem KAHVECİOĞLU'na teşekkürlerimi sunarım. Çalışmaları hep ilgiyle takip ederek, bilgi ve tecrübeleriyle katkı sağlayan Baş Pilot Erdoğan BÖCÜ'ye teşekkürlerimi sunarım. Vaka çalışması bölümüne sunduğu katkılarından dolayı Öğretmen Pilot Ergün ALTUĞ'a teşekkürlerimi sunarım.

Tez savunma jürisinde yer alarak kıymetli görüş ve katkılarını sunan kıymetli jüri üyeleri Doç. Dr. Selçuk EKİCİ, Dr. Öğr. Üyesi Elif KORUYUCU ve Dr. Öğr. Üyesi Alper DALKIRAN'a teşekkürlerimi sunarım.

Bu çalışmalara beni ilk yönlendiren ve çalışmalarından sıklıkla istifade ettiğim Dr. Öğr. Üyesi Vehbi Emrah ATASOY'a sağladıkları değerli katkılardan dolayı teşekkürlerimi sunarım. Bu tez süresince söz, davranış, eylem ve çalışma tarzı ile bana motivasyon kaynağı olan ve desteklerini esirgemeyen Dr. Ahmet Esat SÜZER ve Dr. Hasan SARİBAŞ dostlarıma teşekkürlerimi sunarım.

Gelinen hiçbir aşama kendiliğinden olmuş olamaz. Üzerimde emeği olan ve beni bugünlere taşıyan tüm hocalarıma teşekkürlerimi sunarım.

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

Ali TATLI

İTHAF

Bu çalışma, kısacık vakte sıkışmış insan ömrü nezdinde dahi varlığını beşeriyetin tekâmülüne vakfetmiş ve hatta yaşıyor olmanın ekseri meşakkatlerine rağmen zamanı ve mekânı hiçe saymanın bir yolunu bularak, fikir ve gayretlerini kitaplarda derleyen ve nihayetinde hiç görmedikleri talebelerinin çalışma masalarına taşımayı başarmış pek kıymetli bilim insanlarına ithaf olunmuştur.

Hayatın bütün anlamsızlığını anlamlandırma gayretleri ve muvaffakiyetleri takdire şayandır. İsimlerini tek tek saymakta acze düşeceğim pek kıymetli hocalarıma zaman ve mekâna meydan okurcasına sonsuz saygı ve muhabbetlerimi sunarım.

Ali TATLI

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 ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik 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 ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Ali TATLI

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI.....	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
DANIŞMAN ONAYI.....	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İTHAF.....	vii
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	viii
İÇİNDEKİLER	ix
TABLolar DİZİNİ.....	xi
ŞEKİLLER DİZİNİ	xii
GÖRSELLER DİZİNİ	xiii
SİMGELER DİZİNİ	xiv
KISALTMALAR DİZİNİ	xvi
1. GİRİŞ.....	1
1.1. Çalışmanın Önemi ve Kapsamı	3
1.2. Önceki Çalışmalar.....	6
1.3. Benzer Çalışmalar	8
2. METEOROLOJİK HÂDİSELER VE RAPORLAR	14
2.1. Rüzgâr	14
2.2. Bulutlar.....	15
2.3. Sıcaklık	16
2.4. Rüy et ve Diğer Unsurlar	17
3. VAKA ARAŞTIRMASI; ESTÜ-P	17
3.1. Materyal	19

3.1.1. Havalimanı.....	20
3.1.2. Uçuş eğitim uçakları	21
3.2. Meteorolojik Hâdiselerin Uçuş Eğitimi Üzerindeki Etkisi	23
3.3. Bakım Planlamaları ve Diğer	27
3.4. Bulgular ve Tartışma	28
4. UÇUŞA ELVERİŞLİLİK VE ZAMAN SERİSİ	29
4.1. Teknik Limitler	30
4.2. Düzenlemeler.....	31
4.3. Uzman Görüşü	32
5. YÖNTEM.....	33
5.1. Sinyal Ayrıştırma Yöntemleri.....	33
5.1.1. Empirical mode decomposition (EMD)	33
5.1.2. Variational mode decomposition (VMD).....	36
5.2. Recurrent Neural Network (RNN)	43
5.2.1. Long short-term memory (LSTM).....	43
5.2.2. Gated recurrent unit (GRU).....	45
6. DEĞERLENDİRME	46
6.1. Performans Ölçütleri	46
6.2. İyileştirme Analizi	47
7. UYGULAMA.....	48
8. BULGULAR	52
8.1. SMM Mevsimsel Analizi	56
9. İSTATİSTİKÎ BULGULAR	59
10. TARTIŞMA VE ÖNERİLER	61
KAYNAKÇA	63
EKLER	79
ÖZGEÇMİŞ	

TABLÖLER DİZİNİ

Sayfa

Tablo 1.1. Literatür özeti	11
Tablo 3.1. Hasan Polatkan Havalimanı genel özellikleri.....	21
Tablo 3.2. ESTÜ-P envanterindeki uçakların Faal&Gayr-i faal durumu.....	27
Tablo 8.1. En iyi model sonuçları	53



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Bulut kapalılık oranı	16
Şekil 3.1. ESTÜ-P'nin verimliliğini etkileyen parametreler	19
Şekil 3.2. Uçuş eğitimini olumsuz etkileyen meteorolojik hâdiseler.....	20
Şekil 3.3. Planlanan ve gerçekleşen uçuş sayıları (2019)	23
Şekil 3.4. Gerçekleştirilemeyen uçuş sayıları ve sebepleri (2019).....	24
Şekil 3.5. Gerçekleşen uçuş oranları ile gerçekleştirilemeyen uçuş oranları ve sebepleri (2019)	25
Şekil 3.6. Planlanan ve gerçekleşen uçuş sayıları (2020)	25
Şekil 3.7. Gerçekleştirilemeyen uçuş sayıları ve sebepleri (2020).....	26
Şekil 3.8. Gerçekleşen uçuş oranları ile gerçekleştirilemeyen uçuş oranları ve sebepleri (2020)	27
Şekil 4.1. Cessna 172 SP ve Socata TB-20 uçakları için yan rüzgâr limit çizelgesi	31
Şekil 4.2. LTBY'nin yıl içerisinde gündüz süreleri.....	32
Şekil 5.1. EMD ayrıştırma akış diyagramı	34
Şekil 5.2. Spline enterpolasyonlu EMD ayrıştırma örneği.....	35
Şekil 5.3. Pchip enterpolasyonlu EMD ayrıştırma örneği.....	36
Şekil 5.4. Kutupsal düzlemde analitik sinyal gösterimi	38
Şekil 5.5. VMD ayrıştırma akış diyagramı.....	41
Şekil 5.6. VMD ayrıştırma örneği.....	42
Şekil 5.7. LSTM hücre yapısı	44
Şekil 5.8. GRU hücre yapısı	45
Şekil 7.1. LSTM&GRU tahmin modeli topolojisi.....	49
Şekil 7.2. Ham zaman serisi ve ayrıştırılması	50
Şekil 7.3. UEZS'nin güç spektral yoğunluğu	50
Şekil 7.4. SMM yapısı.....	52
Şekil 8.1. (a) sMAPE, (b) RMSE ve (c) MAE ölçütlerinde normalize sonuçlar.....	57
Şekil 8.2. SMM aylara göre iyileştirme yüzdeleri	58
Şekil 9.1. Güneşlenme süresinin (a) uçuşa elverişli ve (b) sıcaklık etkisinde kalma miktarları	59
Şekil 9.2. Meteorolojik hadiselerin güneşlenme süresini kısıtlama toplam miktarları.....	60

GÖRSELLER DİZİNİ

Sayfa

Görsel 2.1. Bir uçağın yan rüzgâr bileşeni.....	15
Görsel 3.1. Hasan Polatkan Havalimanı'na ait görselleri	21
Görsel 3.2. Socata TB-20 uçağına ait görseller.....	21
Görsel 3.3. Cessna 172 uçağına ait görseller	22
Görsel 3.4. Beechcraft King Air C-90 GTI uçak görseli	23



SİMGELER DİZİNİ

$\mathbb{R}^{1 \times 2}$	: Reel 1×2 matris
$\zeta(\cdot)$	: Ham zaman serisi
$E(\cdot)$	: Enterpolasyon zarfı
$\mu(\cdot)$	: Aritmetik ortalama fonksiyonu
$d(\cdot)$	: Ortalamanın çıkarıldığı fark fonksiyonu
$\sigma(\cdot)$	: Standart sapma
$z(\cdot)$	: Standardizasyon
$u_k(\cdot)$	: Alt zaman serisi (IMF, Modal fonksiyon)
$A_k(\cdot)$	: $u_k(t)$ 'nin zarfı
$\phi_k(\cdot)$	: $u_k(t)$ 'nin fazı
$\omega_k(\cdot)$	: Kök frekansı
$\mathcal{F}[\cdot]$	: Fourier dönüşümü
$\mathcal{H}[\cdot]$	: Hilbert Dönüşümü
$\star$	: Konvolüsyon işlemi
$\Re\{\cdot\}$	: Reel kısım
$\Im\{\cdot\}$	: Sanal kısım
$\text{sgn}(\cdot)$	: Signum fonksiyonu
$\delta(\cdot)$	: Dirac-delta fonksiyonu
$\ \cdot\ _2$	: Euclidian norm
$\ni$	: Öyle ki
$\lambda(\cdot)$	: Langrange çarpanı
α	: Ceza terimi
$\mathcal{L}(\cdot)$	: Lagrangian
n	: Yakınsama sayısı (İterasyon sayısı)
τ	: Zaman adımı parametresi
ε	: Yakınsama toleransı kriteridir
$\in$	: Elemanıdır
$\odot$	: Hadamard çarpma işlemi
$\mathbf{X}$	: Girdi matrisi
$\mathbf{W}$	: Hücre içi ağırlıklar matrisi

$\sigma_h(\cdot)$	: Sigmoid fonksiyonu
$\tau_h(\cdot)$	: Hiperbolik tanjant fonksiyonu
F	: Unut Kapı matrisi
G	: Güncelleme Kapı matrisi
I	: Giriş Kapı matrisi
O	: Çıkış Kapı matrisi
C', C_t	: Hücre Durum matrisi
H', H_t	: Gizli Durum matrisi
R	: Sıfırlama Kapı matrisi
Z	: Güncelleme Kapı matrisi
N	: Aday Gizli Durum matrisi
b	: Bias vektörü
$\bar{d}$	: Gözlem-tahmin arasındaki sapma
$\bar{s}$	: Gözlem-tahmin toplamı
P	: İyileştirme yüzdesi

Alt Simgeler:

$\cdot_{üst}$	: Sinyalin üst kenarı ile ilgili
$\cdot_{alt}$	: Sinyalin alt kenarı ile ilgili
$\cdot_g$	: Güncel sinyal
$\cdot_A$	: Analitik sinyal
$\cdot_b$	: Karşılaştırma modeline ait
$\cdot_t$	: Test modeline ait

Üst Simgeler:

$\hat{\cdot}$	: Fourier dönüşümü
$\tilde{\cdot}$	: Karmaşık eşlenik (quadrature)
$\bar{\cdot}$	: Karşılık gelen gözlem-tahmin işlemi
m	: Örnek sayısı (batch)
l_h	: Girdi sayısı
x	: Gizli katman sayısı

KISALTMALAR DİZİNİ

ADMM	: Alternate Direction Method of Multipliers (Alternatif Yön Çarpanı Metodu)
AIP	: Aeronautical Information Publication (Havacılık Enformasyon Yayını)
DHMI	: Devlet Hava Meydanları İşletmesi
EASA	: European Aviation Safety Agency (Avrupa Havacılık Emniyeti Ajansı)
EMD	: Empricial Mode Decomposition (Ampirik Mod Ayırıştırması)
ESTÜ-P	: Eskişehir Teknik Üniversitesi Pilotaj Bölümü
FTO	: Flight Training Organization (Uçuş Eğitim Organizasyonu)
GRU	: Gated Recurrent Unit (Geçitli Tekrarlayan Birim)
IATA	: The International Air Transport Association (Uluslararası Hava Taşımacılığı Birliği)
ICAO	: International Civil Aviation Organization (Uluslararası Sivil Havacılık Örgütü)
IMF	: Intrinsic Mode Function (İçsel Mod Fonksiyonu)
JARs	: Joint Aviation Requirements (Müşterek Havacılık Gereklilikleri)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
METAR	: Meteorological Aerodrome Reports (Meydan Rutin Hava Raporu)
RMSE	: Root-Mean-Square Error (Ortalama Karekök Hatası)
RNN	: Recurrent Neural Network (Yinelemeli Sinir Ağı)
SGD	: Stochastic Gradient Descent (Stokastik Gradyan İnişi)
SHGM	: Sivil Havacılık Genel Müdürlüğü
sMAPE	: Symmetric Mean Absolute Percent Error (Simetrik Ortalama Mutlak Yüzde Hatası)
SMM	: Seçici Mekanizma Modeli
UEZS	: Uçuşa Elverişlilik Zaman Serisi
VFR	: Visual Flight Rules (Görerek Uçuş Kuralları)
VMD	: Variational Mode Decomposition (Varyasyonel Mod Ayırıştırması)

1. GİRİŞ

Meteoroloji bilimi havacılık faaliyetlerinin gerçekleştirilebilmesini mümkün kılmaktadır. Mevcut meteorolojik durumun analiz edilmesi ve gelecekteki meteorolojik şartların tahminine yönelik çıkarımlarda bulunulması suretiyle çeşitli raporlar (METAR, SPECI, TREND vs.) hazırlanarak havacılık sektörünün kullanımına sunulmaktadır. Bu raporlar havacılık faaliyetlerinin planlanmasında yol gösterici bir görev üstlenmiştir [1,2]. Herhangi bir kararın etkinliği kararı izleyen durumun verilen karara uygunluğu ile belli olur. Karar vermeden önce bu kontrol edilemeyen durumların tahmin edilebilmesi verilecek kararlar üzerinde ki başarı yeteneğini artırır. Yani tahmin yapmak karardaki riski azaltmaktadır [3]. Meteorolojik parametreler ve olaylar uçuş faaliyetlerini doğrudan etkilemektedir. Bu sebeple meteorolojik kaynaklı risklerin azaltılması ve uçuş emniyetinin sağlanabilmesi açısından hâdiselerin önceden bilinmesi havacılık sektörü için oldukça önem taşımaktadır. Uçuşa uygun olmayan zamanların ön görülebilmesi ise uçuş emniyetinin bir gereği olan bakım faaliyetlerinin planlanmasında önemli bir rol oynamaktadır. Uçuş eğitim faaliyetleri açısından düşünüldüğünde ise meteorolojik parametrelerin ve olayların uçuş emniyeti üzerindeki etkisi daha da önemli bir hâl almaktadır.

Adayların uçuş eğitimleri çoğunlukla meteorolojik hâdiselerin gerçekleştiği troposfer katmanında ve bu eğitimlerin önemli bir bölümü de görerek uçuş şartlarında (VFR, Visual Flight Rules) eğitim uçaklarıyla gerçekleştirilmektedir. Uçuş eğitim organizasyonları donanım ve bakım maliyetleri nedeniyle basit yapılı hafif uçakları tercih etmektedirler. Bu sebeple uçakların el kitaplarında yer alan tasarımlarına bağlı yan rüzgâr limitleri iniş ve kalkışlarda göz önünde bulundurulması gereken önemli bir unsurdur. Gerek tecrübesiz pilot adayları gerekse basit yapılı eğitim uçakları uçuş emniyetini olumsuz etkileyebilmektedir. Böylelikle eğitim planlamalarının da önemli bir bölümünü meteorolojik değerlendirmeler oluşturmaktadır.

Açık literatür incelendiğinde, uçuş eğitim organizasyonu (FTO, Flight Training Organization) verimliliğinde meteorolojik koşulların hayatî önemi olmasına rağmen, meteorolojiye dayalı uçuşa elverişlilik konusunda yeterli çalışma olmadığı görülmüştür. Böylece FTO'lar için çizelgelemelerine yardımcı olmak üzere meteoroloji kaynaklı yaklaşımla bir vaka çalışması konu edinilmiştir.

Bu çalışma kapsamında uçuş eğitim organizasyonu olarak faaliyet gösteren ESTÜ-P’de verilen uçuş eğitimi ele alınarak, meteorolojik hâdiselerin uçuş eğitimi üzerindeki etkisi incelenmiştir. ESTÜ-P’nin 2019 ve 2020 yıllarına ilişkin iki yıllık uçuş eğitim süreci değerlendirildiğinde yıllara ait planlanan uçuşların sırasıyla %45’inin ve %25’inin, iki yıllık toplam süreçte ise planlanan toplam uçuşların %33’ünün meteorolojik kaynaklı gerçekleştirilemediği görülmektedir. Bu sonuç, doğal olarak uçuş eğitim organizasyonunun verimliliğini olumsuz bir şekilde etkilemektedir.

Tez çalışması, uçuş eğitiminin daha verimli yapılabilmesi için eğitim uçuşunu etkileyen meteorolojik hâdiseler ve Hasan Polatkan Havalimanı’nın yapısal özellikleri çerçevesinde FTO’ya destek bilgiler sağlayabilecek tahmin modelleri önererek genişletilmiştir. Bu bağlamda kullanılan veri seti ve elde edilmesinde izlenen yönetmelikler, teknik zorunluluklar ve eğitmen pilot tecrübeleri açıklanmaktadır. İzleyen bölümlerde Ampirik Mod Ayırıştırması (EMD, Empirical Mode Decomposition) ve Varyasyonel Mod Ayırıştırması (VMD, Variational Mode Decomposition) yöntemleri ile Geçitli Tekrarlayan Birim (GRU, Gated Recurrent Unit) ve Uzun Kısa Süreli Bellek (LSTM, Long Short-Term Memory) ağ yapılarına yer verilmekte ve bu araçlar çerçevesinde gün içerisinde mümkün uçuş süresinin tahmine yönelik modeller önerilmektedir. Ayırıştırma yöntemleri ve derin öğrenme modellerinin birlikte melez kullanılmasıyla oluşturulan tahmin modellerinin daha başarılı tahmin yeteneğine sahip olduğu ve elde edilen bulgular çerçevesinde çalışmaya konu olan bu modellerin uçuş eğitim organizasyonunun planlama çalışmalarında kullanılabilecek başarılı sonuçlar ürettiği sonucuna varılmıştır. Son olarak meteorolojik rasatlar incelenerek mevsimsel istatistikler ortaya konulmuştur. Yapılan çalışmanın planlama verimliliğini desteklemek için kapsamlı bir referans sağlayabileceği düşünülmektedir. Bu çalışma, araştırmacının bilgisine göre uçuşa elverişlilik tahmininde derin öğrenme yaklaşımlarını kullanan ve ayırıştırma yöntemlerinin derin öğrenme modelleriyle müşterek kullanıldığı melez modeller sunan literatürde ilk çalışma olacaktır. Böylece, yapılan bu çalışma kurulmuş olan veya kurulacak olan uçuş eğitim organizasyonları için bir çerçeve oluşturacaktır.

Yapılan bu tez çalışmasının pratikte öncelikli karşılığı uçuş eğitim organizasyonlarının planlama çalışmalarında verimliliğin arttırılmasına katkı sağlamasıdır. Bakım faaliyetlerinin verimliliğinin arttırılması, uçuş emniyetinin

arttırılması, emisyon ve gürültü gibi çevresel ve ekonomik problemlerin azaltılmasına da dolaylı katkı sağlaması beklenmektedir.

1.1. Çalışmanın Önemi ve Kapsamı

Uçuş emniyeti ve sürdürülebilirlik, hava taşımacılığının vazgeçilmez başlıca konularıdır [4,5]. Bu nedenle havacılıkta veya diğer sektörler içinde emniyet ve sürdürülebilirliği etkileyen parametreler detaylı bir şekilde incelenmelidir [6]. Özellikle havacılıkta yaşanmış kazâların ve olayların arkasındaki sebeplerin anlaşılması, benzer hataların tekrarlanmaması ve kazâların en aza indirilebilmesi açısından oldukça önem taşımaktadır [7,8]. Uçak kazâları; pilot hatası, meteorolojik hâdiseler, uygun olmayan bakım ve yazılım hataları dâhil olmak üzere birçok faktöre bağlıdır [9–13]. Havacılık sektöründeki kazâlar incelendiğinde, kazâların yaklaşık %60-%80'inin insan hatalarından kaynaklandığı görülmektedir [14–17]. Yapılan başka bir çalışmada ise 2000 ve 2011 yılları arasında yapılan uçuşlar incelenmiş ve 309 uçak kazâsının 73'ünün meteorolojik hâdiseler neticesinde meydana geldiği ve bu 73 kazânın 2.488 ölümle sonuçlandığı vurgulanmaktadır [18]. Alaska ve Hawaii'nin de dâhil olduğu Amerika Bileşik Devletleri kapsayan çalışmada 1995 ve 2000 yıllarını kapsayan süreçte meteoroloji kaynaklı 180'inin ölümle sonuçlandığı 206 uçak kazâsının sebepleri incelenmektedir [19]. Havacılık sektöründe meydana gelen kazâ-kırım olayları incelendiğinde insan faktörlerinden sonra meteorolojik hâdiselerin en fazla kazâ-kırımı neden olduğu görülmektedir. Bu nedenle meteoroloji gibi önceden kestirimi zor olan fenomenler için alınan önlemler ve yapılan çalışmalar daha fazla önem taşımaktadır.

Uçuşların planlanması, uçakların bakım zamanları, seyir sürelerinin, hareket rotalarının ve uçuş irtifâsının tespiti gibi birçok konu meteorolojik bilgiler ışığında gerçekleştirilmektedir. Bu nedenlerden dolayı meteorolojik hâdiseler uçuş faaliyetlerini doğrudan etkilemektedir. Meteorolojik kaynaklı risklerin azaltılması ve uçuş emniyetinin sağlanabilmesi için uçuşa uygun zamanların önceden bilinmesi yani doğru bir şekilde tahmin edilmesi gerekmektedir. Başka bir ifade ile doğru uçuş planlamasının yapılması ekonomi, çevre ve emniyet açısından oldukça önemlidir.

Özellikle açık literatürde uçuş eğitim organizasyonlarının verimliliği ve bu verimliliğe têsir eden âmillerden biri olan meteoroloji üzerine yeteri kadar çalışma bulunmamaktadır. FTO'larla ilgili yapılan çalışmalar genel olarak pilot seçimi ve seçim

kriterleri, pilot eğitiminde simülatör kullanımı ve insan kaynakları üzerine yoğunlaşmaktadır [20–26].

Meteorolojik hâdiseler ve öngörüler uçuş eğitiminin ekonomik ve emniyetli sürdürülebilmesi için oldukça önemlidir. Özellikle uçuş eğitim faaliyetleri açısından düşünüldüğünde meteorolojik hâdiselerin uçuş emniyeti üzerindeki etkisi daha da önemli bir hâl almaktadır. FTO'lar bakım ve donanım maliyetleri açısından basit yapılı uçaklarla eğitim hizmeti vermeyi tercih etmektedirler. Adayların uçuş pratiği eğitimleri çoğunlukla meteorolojik hâdiselerin vukû bulduğu troposfer katmanında ve eğitim uçaklarıyla gerçekleştirilmektedir. Gerek pilot adaylarının tecrübesiz olması gerekse basit yapılı eğitim uçaklarının kullanılması meteorolojik hâdiselerin uçuş emniyetini çok daha olumsuz etkilemesine sebebiyet vermektedir. Bu nedenle uçuş eğitim planlamalarının mühim bir bölümünü meteorolojik değerlendirmeler oluşturmaktadır.

Havacılık faaliyetleri, nitelikli yer ekipleri ve uçuş mürettebatı tarafından müşterek yürütülmektedir. Nitelikli personelin eğitimi, devlete ait veya özel teşebbüs uçuş eğitim kuruluşlarınca gerçekleştirilir. Havacılık, ulaşım sektörünün hayatî bir parçasıdır ve tüm teknolojik ilerlemelere rağmen nitelikli işgücüne yani uzman ekiplere ihtiyaç duymaktadır. Uçağın uçuşa hazırlanması için gerekli bakımlar teknisyenler tarafından, uçuş operasyonları ise pilotlar tarafından yürütülmektedir. Pilot adaylarına verilen eğitimler ise yer dersleri ve uygulamalı derslerden oluşmaktadır. Başka bir deyişle, pilot eğitiminin bir kısmı uçuş operasyonlarıdır [27].

Türkiye'de 2018, 2019 ve 2020 yıllarında sırasıyla 515, 546 ve 554 ticarî uçak bulunurken, 2023 yılında toplam ticarî uçak sayısının 750'ye ulaşması beklenmektedir. Bu nedenle her yıl 400 yeni pilota ihtiyaç duyulacağı öngörülmektedir. 2020 yılında Çin'de başlayan ve tüm dünyaya yayılan salgın söz konusu pilot ihtiyacını etkilediğinden, uluslararası kuruluşların raporlarına göre COVID-19 öncesi büyüme rakamlarının 2024 yılından itibaren geri döneceği tahmin edilmektedir [28,29]. FTO'ların karşılaması gereken pilot ihtiyacı sürekli artmakta ve bu artan ihtiyaçla birlikte pratik dersler için uçuşa elverişli günlerin verimli bir şekilde tahlil edilmesi planlamalar açısından büyük önem arz etmektedir.

Uçak Pilotu Lisans Talimatı (SHT-1)'de belirtildiği üzere pilot eğitimi en fazla 55 saati sentetik olmak üzere toplamda en az 195 saatlik bir uygulamalı eğitimi kapsamalıdır. ESTÜ-P'de pratik dersler minimum 221 saat olarak belirlenmiştir [27]. Pratik derslerinin çoğu ancak meteorolojik koşullar uygun olduğunda yapılabilmektedir. Meteorolojik

hâdiseler zaman zaman uygulamalı eğitimi kesintiye uğratmaktadır. Bu nedenle uçuşa elverişli günler yönetmeliklerle belirlenmese de FTO'lar tarafından dikkate alınmalıdır. Eğitimci pilotların, pilot adaylarının, eğitim uçaklarının ve pistin eğitim faaliyetlerine uygunluğu uygulamalı dersleri etkileyen diğer faktörlerdir.

Uygulamalı dersleri etkileyen bir diğer faktör ise ticarî uçuşlardır. Ticarî uçuşların gerçekleştirildiği havalimanlarında aynı zamanda uçuş eğitimlerinin yürütülmesi pratik derslerin sürekliliğini olumsuz etkilemektedir [30]. Ayrıca müşterek kullanılan havalimanlarında FTO'ların dikkate alması gereken bir diğer husus da ticarî uçakların kalkış ve inişlerinin neden olduğu türbülansın, eğitim uçaklarını riske atarak pist kullanımını sınırlandırmasıdır.

Eğitim uçakları, alçak irtifalarda troposfer tabakasında faaliyet gösterdikleri için ticarî uçaklardan daha fazla meteorolojik tésirlere mâruz kalmaktadırlar. Ayrıca bu etkilere ticarî uçaklara göre daha az tolerans gösterirler. Meteorolojik hâdiseler zaman zaman uygulamalı dersleri kesintiye uğratmaktadır [2,31]. 2020 yılında pandemi nedeniyle havacılık faaliyetleri eğitim açısından da etkilenmiş, eğitim organizasyonlarınca planlamalar pandemi koşulları dikkate alınarak gerçekleştirilmiştir. ESTÜ-P'de 2019 yılında planlanan uçuşların %45'inin meteoroloji nedeniyle kesintiye uğradığı görülmektedir. 2020 yılında ise pandemi şartlarında bile planlanan uçuşların neredeyse %25'i meteoroloji nedeniyle kesintiye uğramıştır. Öte yandan 2019 yılında toplam planlanan uçuşların %3'ü ve 2020 yılında planlanan uçuşların %2'si arıza ve diğer nedenlerle kesintiye uğramıştır. Sonuç olarak 2019 yılında planlanan uçuşların %52'si ve 2020 yılında planlanan uçuşların ise %73'ü gerçekleştirilebilmiştir [32,33]. Her halükârda, meteorolojinin uçuş planlamasının verimliliğinde hayatî ehemmiyeti bulunmaktadır.

Bakım; hava aracını her zaman gerekli performansı ve emniyeti sağlayacak durumda, ilk günkü gibi yeni ve iyi çalışır durumda tutmaktır [12,34]. Uçaklar yıl boyunca sürekli hizmette bulunmazlar. Örneğin, yıllık ortalama etkinlik oranları ESTÜ-P envanterinde yer alan uçaklardan Socata TB-20 için %29,5 ve Cessna 172 SP için ise %26 şeklindedir [29]. Uçuşa elverişli günlerin doğru analiz edilmesiyle bazı bakım faaliyetleri verimli hale getirilebilir. Bu nedenle uçuşa elverişli günlerin önceden bilinebilmesi kezâ bakım planlaması için de önemlidir.

Özetle, FTO'lar birçok faktör göz önünde bulundurularak planların dinamik ve sürekli olarak güncellendiği eğitim kurumlarıdır. FTO'lar yetenekleri dâhilinde insan ve

envanter faktörlerini düzenleyebilirler, ancak meteorolojik koşulları değiştiremezler ve etkilerine mâruz kalmak durumundadırlar. Bu nedenle pratik dersler yalnız uçuşa uygun günlerde yapılabilecek olup eğitim faaliyetlerinde uçuşa elverişli günler öncelikli olmaktadır.

Havacılık literatüründe uçuşa elverişlilik tahmini ile ilgili modeller yeteri kadar bulunmamaktadır. Bununla birlikte, diğer alanlarda, melez tahmin modelleri ve çok girişli modeller, yalın tahmin modelleri ve tek girişli modeller ile karşılaştırıldığında daha iyi tahmin performansına sahiptir. Zira, melez teknikler ve çoklu girdiler, doğru bir tahmin için farklı yöntemlerin ve bilgi kaynaklarının avantajlarını kullanmaktadırlar [35–37]. Günümüzde, derin öğrenme teorisinin popülerliği nedeniyle, tekrarlayan sinir ağı (RNN, Recurrent Neural Network) ve onun varyantları olan GRU ve LSTM modelleri, finans, meteoroloji, tıp, uzaktan algılama, çoklu sensör füzyonu vb. gibi farklı sektörlerde melez bir şekilde uygulanmaktadır.

1.2. Önceki Çalışmalar

Atasoy, yüksek lisans tez çalışmasında FTO açısından meteorolojinin önemini inceleyerek 2012 ve 2013 sürecini kapsayan 17.280 METAR verisiyle uçuşa elverişli gün sayısı üzerine istatistiksel bir çalışma yapmıştır. Bu maksatla; sıcaklığın +25°C'den yüksek olduğu, yan rüzgârların 15 kt'dan fazla olduğu, yağmurlu, karla örtülü, şiddetli don yaşanan ve sisli günleri belirleyerek uçuşa elverişli gün sayılarını ve aylara göre dağılımlarını tespit etmiştir [30].

Tatlı, yapmış olduğu yüksek lisans tez çalışmasında uçuş eğitim organizasyonları açısından, Ocak 09' - Haziran 15' ($\approx 6,5$ yıl) arasını kapsayan 58.053 adet METAR verisi kullanarak uçuşa elverişli günler üzerine istatistikî sonuçlar ortaya koymuş ve zaman serilerinde, yapay sinir ağları yöntemlerinden istifade ederek izleyen günün uçuşa elverişli saat miktarı için tahmin çalışması yapmıştır. Bu maksatla çalışmada MLP, TDNN, SRN ve NARX yapıları kullanılarak 10 veri seti üzerinde farklı aktivasyon fonksiyonları, farklı geri besleme yapıları ve farklı sayıda gizli katman hücrelerine sahip 1.824 ağ modelinde toplam 18.240 eğitim gerçekleştirerek tahmin performanslarını değerlendirmiştir. Çalışmada yer alan uçuşa elverişlilik değerlendirmeleri; VFR uçuş prosedürleri, havacılığı etkileyen önemli meteorolojik hâdiseler ve aday pilotlar göz önünde bulundurularak eğitmen pilot tecrübeleriyle uçuş eğitim organizasyonları için tespit edilmiştir. Uçuşa elverişlilik kriterleri olarak;

- vaktin, gün doğumundan yarım saat önce ve gün batımından yarım 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 olup olmadığı
- bulut taban yüksekliğinin 3.000 ft'den az olup olmadığı
- oraj varlığı
- cumulonimbus ve cumulus congestus bulutlarının varlığı
- meydan ihbarlarını gerektiren önemli hava hâdiselerinin varlığı
- şiddetli sağanak yağışların varlığı
- rüyetin 5.000 m'den düşük olup olmaması
- sıcaklığın 5°C 'den düşük olup olmaması

olarak belirlenmiştir. Bazı kriterlerin ve kullanılan hava aracının teknik özelliklerinin zaman-mekânsal tabiatı nedeniyle çalışma Hasan Polatkan Havalimanı'nı ve ESTÜ-P envanterinde kullanılan Cessna 172SP ve Socata TB-20 eğitim uçaklarını konu edinmektedir [2,31,38].

Atasoy ve Ekici çalışmalarında bir uçuş eğitim organizasyonunun kuruluş gerekliliklerini, yönetmeliklerde yer almayan FTO deneyiminden elde edilen göstergeler aracılığıyla ve açısından değerlendirmektedirler. Bir FTO'nun kuruluş gereksinimleri yönetmeliklerle belirleniyor olsa da yönetmeliklerde yer almayan göstergeler aracılığıyla pilot eğitim sürecinin güvenli, sürdürülebilir ve ekonomik bir şekilde gerçekleştirilebileceğinden hareketle çalışmalarını gerçekleştirmişlerdir. Bu göstergeleri, FTO'ların operasyon sürecindeki deneyimlerinden elde etmektedirler. Çalışmada, hâlihâzırda faaliyette olan veya faaliyete geçecek olan FTO'ların etkinliğini ilgilendiren (yönetmelik ve deneyimlerden elde edilen) göstergeler belirlenerek ve göstergelerin organizasyon üzerindeki etkileri incelenerek literatüre sunulmaktadır. Vaka çalışması, FTO işlevi gören Eskişehir Teknik Üniversitesi Pilotaj Bölümü'nü konu edinmektedir. Yönetmeliklerce belirlenmemiş fakat çalışmalar sonucunda gerekli görülen göstergeleri üç ana başlıkta sınıflandırmışlardır: doğal ve yapay engeller, meteorolojik koşullar ve fiziksel ve teknolojik kaynaklar [29].

1.3. Benzer Çalışmalar

Bu bölümde açık literatürde yer alan VMD ve/veya EMD ayrıştırma yöntemleri ile LSTM ve/veya GRU modellerini birlikte içeren çalışmalar incelenmektedir. Bölüm sonunda ise yöntemleri içeren diğer yayınlar tablo halinde verilmektedir.

Bedi ve Toshniwa, çalışmalarında belirtilen sezon, gün ve zaman aralıkları için ortalama ve tepe elektrik talebini tahmin etmektedirler. Araştırmalarını Chandigarh şehrinin Ocak 2013 - Ocak 2018 arasını kapsayan 5 senelik süreçte günlük 15 dk periyotlu elektrik tüketimi verileri içeren veri seti ile gerçekleştirmişlerdir. Önerdikleri EMD tabanlı derin öğrenme yaklaşımının (EMD+LSTM), elektrik talebi zaman serisi tahmininde diğer regresyon modellerinden daha iyi performans gösterdiği sonucuna ulaşmışlardır. Önerilen derin öğrenme yaklaşımının, elektrik zaman serisi verilerinin doğrusal olmayan özellikleriyle verimli bir şekilde başa çıkmak için kullanılabileceği sonucuna ulaşmışlardır [39].

Han ve ark., Belçika elektrik iletim sistem operatörü (ELIA) ve Ulusal Yenilenebilir Enerji Laboratuvarı'ndan (NREL)'den tedarik ettikleri 15 dk periyotlu verilerle rüzgâr gücü tahmini çalışmalarını gerçekleştirmişlerdir. ELIA verileri için, eğitim örneklerinin zaman aralığı 31 Aralık 2015'ten 31 Aralık 2016'ya kadarlık süreci kapsamaktadır. Tahmin modelini test etmek için 31 Aralık 2016'dan 31 Aralık 2017'ye kadar olan veriler test veri seti için ayrılmıştır. NREL verileri için eğitim örneklerinin zaman aralığı 1 Ocak 2011 ile 31 Aralık 2011 arasındadır ve 1 Ocak 2012 ile 31 Aralık 2012 arasındaki veriler, tahmin modelini test etmek için kullanılmaktadır. Yani veriler eğitim ve test için %50-%50 ayrılmıştır. Çalışmalarında kullandıkları VMD-LSTM yaklaşımının tahmin hatasının diğer yöntemden çok daha küçük olduğu sonucuna ulaşmışlardır [40].

Kim ve ark., ofis binasının elektrik yük profili üzerine yaptıkları çalışmada günlük 288 çözünürlüklü veri setiyle araştırmalarını gerçekleştirmişlerdir. Ofis binasının yük profilinin büyük oranda işe gidip-gelme süreleriyle ilişki olduğunu ve tatil günlerinde azaldığını gözlemlemişlerdir. Çalışmalarında Box-Jenkins, destek vektör ve yapay sinir ağları ve de derin öğrenme yaklaşımlarıyla ayrıştırma yöntemlerini kullanmışlardır. Önerilen VMD-LSTM modelinin MAE, RMSE ve MAPE ölçütlerinde en iyi performansı gösterdiği sonucuna ulaşmışlardır [37].

Bandaraa ve ark. CIF 2016 ve NN5 veri setlerinde araştırmalarını gerçekleştirmişlerdir. Araştırmacılar sMAPE ve MASE ölçütlerini referans aldıkları çalışmalarında LSTM'in zaman serilerinin benzerliklerinden etkin bir şekilde

yararlandığını ve bununla birlikte güncel tek değişkenli tahmin yöntemlerinden daha iyi performans gösterebildiğini ifade etmektedirler [41].

Chen ve ark., STL ve EMD ayrıştırmasıyla 2018 yılına ait günlük metro yolcu verileriyle gerçekleştirdikleri tahmini araştırmasında STL-LSTM modelinin LSTM, EMD-LSTM ve SVM modeline göre başarılı olduğu sonucuna ulaşmışlardır. Çalışmalarında MAE, R^2 ve RMSE ölçütlerini referans almaktadırlar [42].

Chacón ve ark., AT&T şirketi için günlük kapanış fiyatı finansal verileriyle 2 Ocak 2018 - 17 Ocak 2020 sürecini eğitim (572 örnek) ve 20 Ocak 2020 - 9 Nisan 2020 sürecini test (515 örnek) için kullanarak bir tahmin doğruluğunu iyileştirme çalışması gerçekleştirmişlerdir. EMD ayrıştırma yöntemini kullandıkları çalışmalarında kullandıkları veri setinde ilk bileşenlerin orijinal zaman serisinden çıkarılmasının, sinyalin genliğinden ödün vermeden LSTM modelinin tahmin doğruluğunu önemli ölçüde geliştirdiği sonucuna ulaşmışlardır [43].

Liu ve ark., Yangtze nehri vaka çalışmasında Ocak 1952 - Aralık 2018 aylık akış verileriyle gerçekleştirdikleri çalışmalarında kodlayıcı-çözücü mekanizmasının ve EMD yönteminin LSTM ile kombinasyonlarının kullanılmasının tahmin performansını arttırdığı sonucuna ulaşmışlardır [44].

Zhou ve ark., elektrik fiyatları üzerine APE, MAPE ve RMSE ölçütlerini referans alarak yaptıkları çalışmalarında LSTM'nin geleneksel makine öğrenimi modellerinden büyük ölçüde daha iyi performans gösterdiğini, heterojen LSTM'nin elektrik fiyatındaki gizli bilgileri tam olarak kullandığını ve tek LSTM'nin zayıf kararlılığının üstesinden geldiğini ifade etmektedirler. Önerdikleri EEMD ayrıştırma tabanlı modelin daha kararlı olduğu ve pratik uygulamalar için daha uygun olduğu sonucuna ulaşmışlardır [45].

Sun ve ark., rüzgâr gücü üzerine yaptıkları araştırmalarında geleneksel yapay sinir ağlarının yanında LSTM modeline de çalışmalarında yer vermişlerdir. 2012'nin son çeyreğine ve 2013'ün ilk çeyreğine ait Çin'deki 33 üniteyi içeren iki rüzgâr santralinden alınan yaklaşık 1.700'er adet veriler, önerilen modelin genelleştirme kabiliyetini test için kullanılmıştır. Çalışmalarına MRE ve RMSE ölçütlerini ve bu ölçütler nezdinde iyileştirmeleri referans almaktadırlar. LSTM, rüzgâr enerjisi serilerinin dalgalanması ve rastgeleliği konusunda BPNN ve ELMAN'dan üstün olduğu, VMD'nin tekil modellerin rüzgâr enerjisi tahmin güvenilirliğini ve kesinliğini destekleyebildiği, K-Means algoritması tarafından yapılan kümeleme analizinin, VMD-LSTM modelinin kabiliyetini önemli ölçüde daha da geliştirebildiği ve uygulanan tüm yaklaşımlar arasında, melez

VMD-Kmeans-LSTM yaklaşımının, çoklu ölçeklerde en iyi performansı gösterdiği sonucuna ulaşmışlardır [36].

Zhang ve ark., rüzgâr hızı ile ilgili çalışmalarında 10 dk örnekleme aralığına sahip İspanyol Sotavento rüzgâr tarlası verileriyle gerçekleştirdikleri çalışmalarında VMD ayrıştırma ve LSTM, BP, RBF, Elman ağlarını kullanarak MAE, MSE ve MAPE ölçütlerinde performans değerlendirmelerini gerçekleştirmişlerdir. Çalışma Lorentz bozucu etkisini kullanması yönü ile diğerlerinden ayrılmaktadır. Önerdikleri yöntemin rüzgâr enerjisi dağıtım düzenlemesi için daha bilimsel ve daha doğru bir temel sağlayabileceği, rüzgâr enerjisinin geliştirilmesini ve kullanımını iyileştirmeye yardımcı olabileceği ve rüzgâr gücünün ekonomik faydalarını iyileştirebileceği sonucuna ulaşmışlardır [46].

Huang ve ark., PM2.5 yoğunluğu üzerine yaptıkları araştırmalarını 35.040 adet eğitim ve 8.756 adet test verisiyle RMSE, MAE, sMAPE ve R^2 ölçütlerinde gerçekleştirmişlerdir. Çalışma verilerinin yaklaşık %75'ini eğitim ve %25'ini test verileri oluşturmaktadır. Bu çalışmanın sonuçları, önerilen yöntemin modelin tahmin hatasını büyük ölçüde azalttığını ve modelin uyumunu iyileştirdiğini göstermektedir. Aynı zamanda önerilen EMD-GRU modelinin tahmin doğruluğunun, geleneksel makine öğrenimi ve tek bir derin öğrenme yönteminden daha yüksek olduğu sonucuna ulaşılmıştır [47].

Huang ve ark., kısa vadeli trafik akış tahmini çalışmalarında 5 dk periyotlu, toplam 17.568 örnek uzunluğunda veri setini %80 eğitim veri kümesine (14.055 örnek) ve %20 test veri kümesine (3.512 örnek) bölerek tahmin çalışmalarını gerçekleştirmişlerdir. VMD'nin en yaygın olarak uygulanabilir algoritma, WD'nin veri ön işlemeden sonra oldukça başarılı olduğu ve EEMD'nin oldukça iyi gürültü direncine sahip olduğu sonucuna ulaşmışlardır [48].

Jianwei ve ark., enerji fiyatları üzerine gerçekleştirdikleri araştırmalarında Ekim 1983 - Eylül 2018'e 420 örnekli aylık doğal gaz fiyat verisi, 1974 - 2018'e 537 örnekli aylık ham petrol fiyatı verisi ve 1 Ocak 2011 - 17 Eylül 2018'e 2040 örnekli günlük karbon fiyatı ile çalışmalarını gerçekleştirmişlerdir. Bulguları önerdikleri modelin MAD, RMSE ve MAPE'de en düşük Dstat'da ise en yüksek skorları alarak geleneksel modellerle kıyaslandığında üstünlük elde ettiği yönündedir [49].

Tablo 1.1. *Literatür özeti*

Çalışma	Yıl	Kullanılan Yöntemler	Ölçütler
[50]	2017	AR-ANN	RMSE, MAE
[51]	2017	ANN	RMSE, MAE
[52]	2017	AR, VAR, WLS-MARMA	RMSE, MAE
[40]	2019	VMD-LSTM, PER, WT, BP	RMSE, NRMSE, MAPE
[37]	2018	ARIMA, GPR,SVR, NARX, EMD-NARX, VMD-NARX, LSTM, EMD-LSTM, VMD-LSTM	RMSE, MAE, MAPE
[53]	2020	WT, BPNN, ELM, LSTM, Bi-LSTM, SAE-LSTM	RMSE, MAE, MAPE, RMSPE, U1, U2, R ²
[54]	2019	LSTM, LSTM&GRU	RMSE
[55]	2020	PCA, LSTM, LSSVM, RNN	RMSE
[56]	2019	ARIMA, SVM, TSM, LASSO, LSTM, TSM-LASSO, TSM-LSTM, LLIFA	RMSE, MAPE
[57]	2018	LR,RFR, SVR, EN, SGDR, BR, LL, PAR, OMP, AE-LSTM, CNN-LSTM	RMSE, MAE, MAPE
[58]	2019	CNN-LSTM	MSE
[59]	2019	PM, ARIMAX, MLP, LSTM, ALSTM	RMSE, MAE, MAPE
[60]	2019	ARIMA, SVR, BPNN, CNN, LSTM, RNN	RMSE, MAE, MAPE, R ²
[61]	2019	ATT-BLSTM, ATT-LSTM, LSTM, BPNN, SVR	RMSE, MSE, MAE, R ²
[62]	2020	KL-MLP, KL-LS-SVM, KL-MLP-LSTM	RMSE, ARE, TNAE, SNAE
[36]	2019	BP, ELMAN, LSTM, VMD-BPNN, VMD-ELMAN, VMD-LSTM, VMD-Kmeans-LSTM	RMSE, MRE, P _{rmse} , P _{mre}
[63]	2020	BPN, LSTM, GRU	RMSE, MAE
[64]	2019	ANN, SVM, LSTM, DWT-FFT	SD
[65]	2020	LSTM	MSE
[66]	2020	LSTM-CNN, BLR, XGBoost, LSTM, CNN	TPR, FPR
[42]	2020	LSTM, STL-LSTM, EMD-LSTM, SVM	RMSE, MAE, R ²
[67]	2019	LSTM, SVM, ELMAN, SMA, DMA, PSO (parametre optimizasyonu için)	RMSE, MAE
[68]	2019	SVR, LSTM, ARIMA, SVR-LSTM, Fusion- KNN	RMSE, MAE, MAPE
[44]	2020	Vanilla LSTM, Stacked LSTM, En-De-LSTM, EMD	RMSE, R ² , WI, LMI

Tablo 1.1. (Devam) *Literatür özeti*

Çalışma	Yıl	Kullanılan Yöntemler	Ölçütler
[69]	2019	RBF, ELMAN, LSTM, V-LSTM, V-LSTM-KDE, V-PSOR-LSTM, V-PSOR-LSTM-KDE	RMSE, MSE, MAE, MAPE
[70]	2017	ARIMA, MA, HES	RMSE, MAE, MAPE
[71]	2020	CNN-LSTM	RMSE, MAE
[72]	2020	ARFIMA, ARIMA, LSTM, ARFIMA-LSTM, GRNN	RMSE, MSE, MAPE
[73]	2020	MO-LSTMs	RMSE, MSE, MAPE, R ²
[74]	2020	LSTM-STOM, MLP, CNN, SVR, GRNN, BPNN, ARIMA	RMSE, MAE
[75]	2019	HLSTM-RNN, LSTM-RNN	WER
[76]	2019	M-LSTM, ST-LSTM	RMS
[77]	2017	LSTM, RNN, ARIMA, SVM, RBF, SAE	MSE, MAE, MRE
[78]	2002	MLP, LSTM	NRMSE
[79]	2018	Vanilla LSTM, RNN, GRU	MSE
[80]	2020	LSTM, AdaBoost, KNN, CNN	TPR, FPR
[81]	2019	RMAPS-CHEM, CUACE, LSTM, BP	RMSE, MAE, R ²
[45]	2019	SVR, BPNN, GTB, DTR, Vanilla LSTM Stacked LSTM, EEMD-LSTM, EEMD-LSTM-SMBO	RMSE, MAPE, APE
[82]	2019	ANN, LSTM, LSTM-FC	RMSE, MAE
[83]	2020	PSO-LSTM	MAPE
[84]	2019	Holt–Winters, ARIMA, ELM, RNN (Relu), RNN (Silu), LSTM	MSE, MAPE, MAD
[85]	2019	ARMA, BPNN, LS-SVM, EMD, EEMD	RMSE, MSE, MAE
[86]	2017	WT, VMD, BP, DE	RMSE, MAE, MAPE, TIC
[87]	2012	EMD-FNN	MSE, MAE, MAPE
[88]	2020	VMD, ANFIS	RMSE, MSE, MAE, MAPE
[89]	2020	BPNN, ARMA, ARFIMA, LSTM	RMSE, MSE, MAE, MAPE, U, MEAN, VARIANCE
[90]	2020	MSTL, STL, Prophet, TBATS, Fourier, FFORMA, Dynamic-Harmonic-Regression, LSTM	sMAPE, MASE

Tablo 1.1. (Devam) Literatür özeti

Çalışma	Yıl	Kullanılan Yöntemler	Ölçütler
[91]	2018	EMD, SVR, Naive model, ARIMA	MAE, Z-statistic
[92]	2018	GM (1,1), ARIMA, BP, SVM, ELM, BP-EMD, BP-VMD, ELM-EMD	RMSE, MAPE, R^2
[93]	2018	VMD, BP, FF (BP optimizasyonu)	RMSE, MAE, MAPE
[94]	2020	VMD, CNN, LSTM, RFR, SVR	RMSE, MAE, MAPE, DMstat
[95]	2017	EMD, MA	RMSE, MAE, MAPE, MASE, U
[96]	2019	ANN, EMD	NMSE, Dstat
[97]	2019	VMD, EMD, RVFLN, BPNN, ARIMA, LSSVR, ANFIS, IT2FNN, RNN, ELM	RMSE, MAE, MAPE
[98]	2020	LSTM, GRU, AttGRU, VMD-GRU, VMD-AttGRU	RMSE, MAE, MAPE, TIC, Dstat
[35]	2020	VMD-SVR, ARMA, GBRT, BPNN, EEMD-BPNN	RMSE, MAE, NSE
[99]	2018	VMD, EMD, ANN, RF, ANFIS	RMSE, MAE, CE, IOA, R^2 , MSRE, MS4E
[100]	2020	Bi-LSTM, HS	RMSE, MAE, R^2 , NSE
[101]	2020	GRU, LSTM, SMA, GRU-LSTM	RMSE, MSE, MAE, R^2
[46]	2019	VMD, LSTM, BP, RBF, Elman - LD	MSE, MAE, MAPE
[102]	2020	GRU, LSTM, ANN	MAE, NSE, EQ
[103]	2020	GRU, LSTM	RMSE, MSE
[47]	2021	EMD, GRU, SVM, DTR, GBDT, RF, RNN, LSTM	RMSE, MAE, sMAPE, R^2
[104]	2020	VMD, GA, BP, Elman, RBF	RMSE, MAE, MAPE
[105]	2020	CNN, GRU, LSTM, LR, DT, SVR	RMSE, MSE, MAE
[106]	2020	Bi-LSTM, LSTM	RMSE
[107]	2019	SARIMA, ANN, WT	RMSE, MAE, MAPE
[108]	2021	SVM, KELM, ANN, VMD-ANN, QRLSTM, CM, HM	PICP, PINRW
[48]	2021	EMD, EEMD, CEEMDAN, VMD, WD, WPD, BiLSTM, LSTM, RF, PS-LSSVM, EEMD-BiLSTM, WD-BiLSTM	RMSE, MAPE, R^2
[109]	2021	VMD, ARIMA	RMSE, MSE, MAE, MAPE, RRMSE, Error

Tablo 1.1. (Devam) *Literatür özeti*

Çalışma	Yıl	Kullanılan Yöntemler	Ölçütler
[110]	2019	ANN, ARIMA, BiGRU, EEMD, EMD, GARCH, GRU, VMD	R^2 , DA, MAE, MAPE, RMSE, MSE
[111]	2020	Elman, GRU, LSTM, GSA-GRU	RMSE, MAE
[112]	2021	GA, GRU	RMSE, MAPE
[113]	2018	GRU, LSTM	MSE
[114]	2020	BPNN, RNN, LSTM, MHPSO-GRU	RMSE, MAE, MAPE, MER
[115]	2020	SVR, BPNN, RNN, LSTM, GRU	MSE
[49]	2019	ICA, SVR, GRU, VMD, LSTM, IC@S	RMSE, MAPE, MAD, Dstat
[43]	2020	EMD, LSTM	MAPE, WAPE, DA, U, ARV, SampEn
[39]	2018	RNN, LSTM, EMD-RNN, EMD-LSTM	RMSE, MAPE

2. METEOROLOJİK HÂDİSELER VE RAPORLAR


Mevcut meteorolojik durumun analiz edilmesi ve gelecekteki meteorolojik şartların seyrine yönelik çıkarımlarda bulunulması suretiyle çeşitli raporlar (METAR, SPECI, vs.) hazırlanarak havacılık sektörünün kullanımına sunulmaktadır. Bu raporlar hava alanında hüküm süren meteorolojik hâdiseleri göstererek havacılık faaliyetlerinin planlanmasında yol gösterici bir görev üstlenmiştir. Meydan rutin hava raporları bir veya yarım saatlik aralıklarla yayınlanmaktadır. SPECI, izleyen METAR rasatları arasında havacılığı ilgilendiren önemli meteorolojik hâdiseler olması durumunda yayınlanan METAR ile benzer formata sahip bir rapordur. Meteorolojik raporlar gerekli tedbirlerin alınması ve uçuş emniyetinin sağlanmasında, pratik eğitimlerinin gerçekleştirilip gerçekleştirilmeyeceğine karar verilmesinde ve pilot adaylarının meteoroloji konusundaki genel bilgilerinin artırılmasında kullanılmaktadır.

2.1. Rüzgâr

Rüzgâr, atmosferin yüksek basınç alanlarından alçak basınç alanlarına doğru oluşan yatay veya dikey hava akımları olarak ifade edilmektedir. Hava taşımacılığını ve özellikle de hafif uçaklarla gerçekleştirilen uçuş eğitimlerini etkileyen en önemli meteorolojik hâdiselerden birisidir. Uçuşu etkileyen rüzgârlar; yüksek seviye rüzgârları, yer rüzgârları, dikey rüzgâr shearı olmak üzere üç grupta toplanmaktadır. Hava aracının hareket yönü

referans alınarak; ön rüzgâr (karşı rüzgâr), arka rüzgâr ve yan rüzgâr (cross wind) olarak sınıflandırılırlar [116].

Eğitim uçakları, ticarî uçaklara göre daha basit yapılıdır ve meteorolojik koşullardan daha fazla etkilenirler. Yan rüzgârlar eğitim uçaklarının kullanımını sınırlayan önemli bir faktördür. Uçak üzerindeki yan rüzgâr bileşeni etkisi Görsel 2.1'te izah edilmektedir. Buna göre rüzgârın theta açısı (θ) üzerindeki kosinüs bileşeni yan rüzgârdır ve uçak üzerindeki yan etkiyi temsil etmektedir.



Görsel 2.1. Bir uçağın yan rüzgâr bileşeni


İniş ve kalkış fazlarında rüzgâr şiddet ve yönü özellikle göz önünde bulundurulması gereken en önemli âmiller arasındadır. Rüzgâr têsiri, uçakların hız ve pozisyonunda mühim değişikliklere sebep olmaktadır. Rüzgâr, dönüş oranı sapmalarına ve takip edilmesi gereken rota ile uçuş başının uyumsuzluğuna neden olmakla beraber hava aracı yakıt tüketimi üzerinde önemli bir etmendir. Hafif veya orta ağırlık segmentinde yer alan hava araçlarında, rotadan sapmalara ve dolayısıyla pilotun iş yükünde artmaya sebebiyet vermektedir. Hava araçlarının tasarımlarına bağlı farklı rüzgâr limitleri vardır ve hava araçları kendi limitleri dâhilinde operasyonlarını gerçekleştirmektedir.

2.2. Bulutlar

Bulutlar, kalınlığına bağlı olarak siyah, gri ve beyaz renklere olmaktadır. Seviyelerine ve mevsimlere göre ise içerilerinde buz kristalleri, su damlacıkları veya aşırı soğumuş su damlacıkları bulundurmaktadırlar. Bulutların sınıflandırılması; yüksekliklerine göre “yüksek irtifâ” bulutları (Ci, Cs, Cc), “orta irtifâ” bulutları (As, Ac),

“alçak irtifâ” bulutları (St, Sc) ve “dikey gelişmeli” bulutlar (Cb, Cu, Ns), oluşumlarına göre ise “kümülüform” tipi bulutlar ve “stratiform” tipi bulutlar şeklinde yapılabilir [116]. Dikey gelişen cumulonimbus (Cb) bulutları orajla birlikte görülmekte ve gök gürültüsü, sağanak yağışlar, fırtına, dolu gibi hava hâdiselerine neden olmaktadır. Bulut içerisindeki buzlanma, şiddetli türbülans ve düşük rüyet uçuş operasyonlarını tehdit etmektedir. Nimbostratus (Ns) bulutları da benzer şekilde şiddetli türbülans, buzlanma ve zayıf görüşe neden olmaları dolayısıyla havacılık faaliyetlerini oldukça olumsuz etkilemektedir. Eğitim uçuşları başta olmak üzere tüm uçuşlar için en tehlikeli bulut tipi Cumulonimbus (Cb) bulutlarıdır.

Sinoptik rasatta bulutluluk 8 okta üzerinden değerlendirilmekte ve gökyüzünün 8 eşit parçaya bölündüğü kabul edilerek ne düzeyde kapalılık olduğu ölçülmektedir. Rasatta bulutluluk 0/8 ise açık (sky clear), bulutluluk 8/8 ise gökyüzünün kapalı (overcast) olduğunu göstermektedir. Şekil 2.1’de bulut ölçümüne ait görsel anlatım örneği yer almaktadır. Buna göre şekilde 2/8 okta ve 3/8 okta olmak üzere iki bulut yer almaktadır.



Şekil 2.1. Bulut kapalılık oranı[38]

Uçuş eğitiminin emniyetli bir şekilde yürütülebilmesi için bulut kapalılık oranı, bulut taban yüksekliği gibi veriler titizlikle değerlendirilmelidir. Bulutların uçuş operasyonları üzerindeki olumsuz etkileri; rüyette azalma, buzlanma, yağış ve türbülans olarak özetlenebilir. Bulut tavan yüksekliğinin düşük olması ve kapalılık oranının yüksek olması operasyon alanını daraltmaktadır.

2.3. Sıcaklık

Havanın yoğunluğu ve basıncı sıcaklık değişimi ile doğrudan ilişkilidir. Standart atmosferde sıcaklığın yükseklikle değişimi, basıncın yükseklikle değişimine oranla daha yavaş olduğu için hava yoğunluğu, yüksek irtifalarda düşmektedir. Hava yoğunluğu ve

atmosferik basınç ve sıcaklık gibi meteorolojik fenomenler uçak performansları üzerinde oldukça etkilidir. Şöyle ki, sıcaklık havanın yoğunluğunu azaltarak taşıma kuvvetinde azalmaya, motorun verimliliğinde azalmaya ve dolayısıyla kalkış mesafesinin uzamasına ve düşük tırmanma varyosuna neden olmaktadır. Yine aşırı sıcaklıklar öğretmen pilotların performansının düşmesine neden olmaktadır. Buzlanma şartlarında buz önleyici sistemleri olmayan uçaklar kontrol yüzeylerinde kaba buzlanmanın oluşmasıyla kullanılamamaktadır. 5°C ‘nin altında ise pitot statik sistemlerin dar hava giriş deliklerinde tıkanma ve daralma olmaması için ısıtıcıların açılması emniyet bakımından gerekli görülmektedir.

2.4. Rüyet ve Diğer Unsurlar

Eğitim uçakları operasyonlarının önemli bir bölümünü VFR şartlarda gerçekleştirmektedir. Bu nedenle belirli bir nesnenin çıplak gözle teşhis edilebileceği veya gece rasatları için genel aydınlatmanın gün ışığı seviyesine çıkarılması halinde nesnenin teşhis edilebileceği en uzak mesafe olarak tanımlanan “rüyet” veya “görüş mesafesi” eğitim uçuşları için fazlaca önem taşımaktadır [116]. Kısaca rüyet/görüş, belirli bir cismin görülebildiği en uzak mesafe olarak tanımlanmaktadır. Çeşitli hava hâdiseleri rüyeti olumsuz etkileyebilmekte ve görüş mesafesini düşürmektedir. Başlıca bu hava hâdiseleri sis, pus, kum fırtınası, sağanak yağış ve dumandır. Stratus (St) bulutunun yer yüzeyinde meydana gelmiş hali olan sis, rüyeti azaltarak can ve mal kaybına sebebiyet veren hâdiselerin başında gelmektedir. Özellikle eğitim uçuşlarında yatay ve düşey rüyet hayatî öneme sahip olduğundan uçuş operasyonlarının yapılacağı bölgeler için sis analizinin yapılması ve hava kirliliği yoğunluğu, senelik yağış oranı, senelik yağış çeşidi gibi rüyeti azaltacak unsurların dikkatle incelenmesi gerekmektedir.

3. VAKA ARAŞTIRMASI; ESTÜ-P

ESTÜ-P, sektörün artan pilot ihtiyacını karşılamak üzere uluslararası sivil havacılık standartları nezdinde pilot yetiştiren bir uçuş eğitim organizasyonudur. Bölüm, Eskişehir Teknik Üniversitesi İki Eylül Kampüsü’nde yer almakta ve pilotaj eğitimi faaliyetlerini 1986 yılından beri sürdürmektedir. Eğitim, Joint Aviation Requirements (JARs) gerekliliklerini karşılamak durumundadır. Eğitim faaliyetleri EASA’nın öngördüğü standartlar çerçevesinde sürdürülmektedir. Eğitimde kalite gözetilerek EASA organizasyonunun öngördüğü 750 saatlik programın ötesinde temel programın %215’sine denk gelen 1.611 saatlik bir eğitim programı uygulanmaktadır. Toplamda 8

eğitim dönemini kapsayan akademik eğitimin ilk 3 dönemi ağırlıklı olarak genel havacılık bilgisine yönelik teorik eğitime ayrılmıştır. Eğitimin ilerleyen safhasında pratik eğitimlerine de yer verilmesiyle eğitim teorik/pratik müşterek sürdürülmekte ve adaylar entegre hava yolu nakliye pilotu eğitimini tamamlamaktadır. Eğitim safhaları ve karşılık gelen toplam uçuş saatleri;

I. Başlangıç

1. Safha: Toplam Uçuş Eğitimi 14:30 (Sa)

i. İntibak

2. Safha: Toplam Uçuş Eğitimi 22:00 (Sa)

i. Trafik paterni

ii. Hava hareketleri

iii. Seyrüsefer uçuşları

3. Safha: Toplam Uçuş Eğitimi 22:00 (Sa)

i. Seyrüsefer uçuşları

ii. Hava hareketleri

II. Tekâmül

4. Safha: Toplam Uçuş Eğitimi 110:30 (Sa)

i. İntibak

ii. Temel alet

iii. Gündüz trafik paterni

iv. Gece uçuşu

v. Gece seyrüsefer uçuşu

vi. Prosedürel alet

vii. Prosedürel alet seyrüsefer

viii. Çok motor intibak eğitimi

ix. Çok motor aletli uçuş eğitimi

5. Safha: Toplam Uçuş Eğitimi 3:00 (Sa)

i. UPRT Eğitimi


III. Çok Motor ve MMC

6. Safha: Toplam Uçuş Eğitimi 15:00 (Sa)

i. PF veya PNF eğitimi

şeklinde uygulanmaktadır. Buna göre genel toplam uçuş eğitimi 221:00 (Sa) verilmektedir. Mezun öğrencilere CPL(A)/IR(A) lisansını alabilmeleri sağlanarak çok pilotlu, çok motorlu uçaklarda ikinci pilot olarak görev yapabilecekleri düzeyde ticarî hava taşımacılığında çalışabilme imkânı sunulmaktadır. Eğitim boyunca ticarî hava taşımacılığı yapmayan uçaklarda ve tek pilota sertifikalı ticarî hava taşımacılığında sorumlu pilot olarak uçuş becerileri elde etmektedirler [27,117].

ESTÜ-P uçuş eğitimlerini uluslararası bir havalimanı olan Hasan Polatkan Havalimanı'nda gerçekleştirmektedir. Pilotaj eğitiminin yanı sıra iç ve dış hat uçuşlarda da bu havalimanı kullanılmaktadır. ESTÜ-P envanterinde 13 eğitim uçağı, üç uçuş simülatörü ve çeşitli akademik imkânlarıyla hizmet vermektedir. Uçuş eğitiminde kullanılmak üzere envanterinde bulundurduğu uçaklar Socata TB-20 Trinidad, Cessna 172 SP ve çift turboprop motorlu Beechcraft King C90 GTI'dır. ESTÜ-P'nin verimliliğini etkileyen parametrelerinin; eğitim sistemi, maddi kaynaklar, insan kaynakları ve coğrafi özellikler olmak üzere 4 ana başlıkta toplanması mümkündür. Şekil 3.1'de bu parametreler gösterilmektedir. Bu çalışma kapsamında ise coğrafi özelliklerin altında yer alan meteoroloji konusu detaylı olarak ele alınmıştır.




Şekil 3.1. ESTÜ-P'nin verimliliğini etkileyen parametreler

3.1. Materyal

Uçuş eğitimi, eğitim uçaklarıyla gerçekleştirilmektedir. Uygulama derslerinin temelde üç farklı safhada gerçekleştirildiği söylenebilir. Bunlar; kalkış, seyir (uçuş) ve iniş fazlarıdır. Kalkış ve iniş fazlarının uçağın zemin ile temas ettiği aşamalar olması nedeniyle bu süreçte pist kullanılmaktadır. İniş ve kalkış fazları dışında kalan uçuşlarını yüksek irtifâlarda gerçekleştiren ticarî yolcu uçakları, meteorolojik hâdiselerden önemli derecede etkilenmemektedirler. Hem iniş/kalkış fazlarında hem de seyir fazında alçak

irtifâlarda faaliyet göstermek durumunda olan eğitim uçakları ise meteorolojik hâdiselerden önemli derecede etkilenmektedirler. Uçuş eğitimini etkileyen önemli meteorolojik hâdiseler şunlardır; hava sıcaklığı, bulut, şiddetli don ve kar, sis ve pus, şiddetli yan rüzgâr ve sağanak yağmur [2,18,19,29–32,38]. Şekil 3.2’de uçuş eğitimini olumsuz etkileyen meteorolojik hâdiseler verilmektedir. Bu bölümde pist, eğitim uçakları ve önemli meteorolojik hâdiseler açıklanmaktadır.



Şekil 3.2. Uçuş eğitimini olumsuz etkileyen meteorolojik hâdiseler

3.1.1. Havalimanı

Hasan Polatkan Havalimanı uçuş eğitiminde kalitenin artırılması ve pilot ihtiyacının karşılanması maksadıyla ilk olarak 1989 tarihinde “Anadolu Havalimanı” adıyla havacılık birimlerince kullanılmak üzere eğitim alanı olarak inşa edilmiştir. Zamanla ulusal ve uluslararası yolcu taşımacılığına açılarak kullanım amacı genişletilmiştir. Hasan Polatkan Havalimanı’nın 09-27 yönünde tek pisti bulunmaktadır. Önceleri 2.552 metre uzunluğunda ve 30 metre genişliğinde asfalt kaplama olan pist, daha sonra 3.000 metre uzunluğa ve 45m genişliğe çıkarılarak beton kaplama haline getirilmiştir. Meydan deniz seviyesinin 790 m (2.599 ft) üzerinde konumlanmıştır. Hasan Polatkan Havalimanı asfalt kaplama doğu apronu ve beton kaplama batı apronu olmak üzere 2 adet apronuyla yolcu trafiğine hizmet etmektedir. Genel havacılık faaliyetlerinde kullanılmak üzere 1 adet beton kaplama aprona sahiptir. Genel havacılık maksatlı apron ise eğitim ve diğer genel havacılık uçakları tarafından park maksadıyla kullanılmaktadır. Hasan Polatkan Havalimanı’nın özellikleri Tablo 3.1’de verilmiştir.

Tablo 3.1. *Hasan Polatkan Havalimanı genel özellikleri*

Özellik	Açıklama
IATA/ICAO tanıtım kodu	AOE/LTBY
Meydan yüksekliği	2.599 ft
Pist istikâmeti	09/27 (092.77°/272.70°)
Pist uzunluğu	3.000 m
Pist genişliği	45 m
Koordinatları	D 39° 48' 45" N – 030° 31' 14" E

Hasan Polatkan Havalimanı'na ait görsellere Görsel 3.1'de meydan krokisine ise EK-1 bölümünde yer verilmiştir.



Görsel 3.1. *Hasan Polatkan Havalimanı'na ait görselleri*

3.1.2. Uçuş eğitim uçakları

TB-20 uçağı Socata firması tarafından üretilmiştir. Tek motorlu ve çift pilotlu bir eğitim uçağıdır. Alttan kanatlı, pervane hatvesinin sabit süratli, burundan tekerlekli ve iniş takımları içeri alınabilir olması uçağın belli başlı özellikleridir.

ESTÜ-P envanterinde TC-AUD, TC-AUE, TC-AUF, TC-AUP, TC-AUS, TC-AUU çağrı kodlarıyla toplam 6 adet Socata TB-20 uçağı bulunmaktadır. Görsel 3.2'de Socata TB-20 uçağına ait görseller verilmiştir.



Görsel 3.2. *Socata TB-20 uçağına ait görseller*

Cessna 172 SP uçağı üstten kanatlı-destekli, tek motorlu, 4 kiři kapasiteli Cessna modelidir. Dünyada oldukça popüler ve en çok üretilen eğitim uçağıdır. İlk kez 1955 yılında üretilmiş olup en kararlı eğitim uçaklarından birisidir ve Genel Havacılık Uçağı segmentinde en güvenilir uçak olarak kabul edilmektedir. Düşük bakım masrafları, fiyat/performans oranı ve kullanım kolaylığı nedeniyle tercih edilmektedirler. Cessna 172 SP, dünyada birçok uçuş okulu tarafından kullanılıyor olmakla birlikte Türkiye’de faaliyet gösteren uçuş okullarının en fazla tercih edilen eğitim uçağı durumundadır.

ESTÜ-P envanterinde TC-SHN, TC-SHO, TC-SHR, TC-SHS, TC-SHT çağrı kodlarıyla toplam 5 adet Cessna 172 SP uçağı bulunmaktadır. Görsel 3.3’de Cessna 172 SP uçağına ait görseller verilmektedir.



Görsel 3.3. Cessna 172 uçağına ait görseller


ESTÜ-P envanterinde TC-SHA, TC-SHB çağrı kodlarıyla toplamda 2 adet Beechcraft King Air C-90 GTI uçağı yer almaktadır. Sahip olduğu yakıt tüketimi, genel sistem özellikleri ve bakım özellikleri avantajları nedeniyle tercih edilmişlerdir. Beechcraft King Air C-90 GTI uçakları uçuş eğitiminin çok motor safhasında kullanılmaktadır. Görsel 3.4’de Beechcraft King Air C-90 GTI uçağına ait görsel verilmektedir.



Görsel 3.4. Beechcraft King Air C-90 GTI uçak görseli


3.2. Meteorolojik Hâdiselerin Uçuş Eğitimi Üzerindeki Etkisi

ESTÜ-P bölümünce tutulan 2019-2020 uçuş kayıt verilerine dayanarak uçuş eğitimini olumsuz etkileyen meteorolojik hâdiseler nedeniyle yapılamayan uçuşlar ve uçuş eğitimi üzerindeki etkisi incelenmiştir. İlk olarak 2019 yılına ait uçuşlar ele alınmıştır. Şekil 3.3’de 2019 yılına ait planlanan ve gerçekleşen uçuşlar verilmektedir. Şekil 3.3’den de anlaşılacağı üzere planlanan uçuşlar ile gerçekleşen uçuşlar arasında büyük farklılıklar bulunmaktadır. Özellikle Aralık ayında planlanan ve gerçekleşen uçuşlar arasındaki fark en büyüktür. Ocak ayı içerisinde ise yapılması planlanan uçuş sayısı 320 iken bu uçuşların sırf 93 tanesi gerçekleştirilebilmiştir. Bahar ve yaz aylarında ise bu farkların azaldığı görülmektedir.




Şekil 3.3. Planlanan ve gerçekleşen uçuş sayıları (2019)

Şekil 3.4’de ise aylara göre gerçekleştirilemeyen uçuş sayıları ve gerçekleştirilememe sebepleri yer almaktadır. Bu sebepleri meteorolojik hâdiseler, arıza ve diğer olmak üzere üç gruba ayırmak mümkündür. Ocak ve Aralık aylarında gerçekleştirilemeyen uçuşların büyük oranını meteorolojik hâdiseler oluşturmaktadır. Ocak ayında uçuşları etkileyen bir başka önemli faktör ise “diğer” olarak adlandırılan olaylardır. Diğer olaylar içerisinde uçuş eğitim okulunda yapılan denetimler, öğrenci ve öğretmenden kaynaklı problemleri saymak mümkündür.




Şekil 3.4. Gerçekleştirilemeyen uçuş sayıları ve sebepleri (2019)

2019 yılının tümüne ait gerçekleşen uçuş oranları ile meteorolojik hâdiseler, arıza ve diğer olaylardan kaynaklı gerçekleştirilemeyen uçuş oranları Şekil 3.5’de verilmektedir. Gerçekleştirilemeyen uçuşların en yaygın sebebinin meteorolojik hâdiseler olduğu açıkça görülmektedir. Tüm yıl boyunca uçuşların %45’ i meteorolojik hâdiselerden kaynaklı yapılamamaktadır. Bu oranı %2 ile diğer olaylar ve %1 ile arızadan kaynaklı olaylar takip etmektedir. Uçuşların yarısının yapılamama sebebinin meteorolojik hâdiseler olması doğal olarak ESTÜ-P’nin verimliliğini de önemli derecede etkilemektedir.




Şekil 3.5. Gerçekleşen uçuş oranları ile gerçekleştirilemeyen uçuş oranları ve sebepleri (2019)

2020 yılına ait planlanan ve gerçekleşen uçuşlar Şekil 3.6’da sunulmaktadır. Kış aylarında gerçekleştirilemeyen uçuş sayıları diğer aylara kıyasla daha fazladır. 2019 yılında olduğu gibi planlanan ve gerçekleştirilemeyen uçuşlar arasındaki büyük farklardan biri de Ocak ayında görülmektedir. Ocak ayında 432 uçuş planlanmışken sadece 121 uçuş gerçekleştirilebilmiştir. 2020 yılının bahar ve yaz aylarında bu farkların azaldığı görülmektedir. 2019 yılından farklı olarak Nisan ve Mayıs ayları içerisinde 2 uçuş planı yapılmış ve 2 uçuş da gerçekleştirilmiştir. Bu aylarda planlanan ve gerçekleştirilen uçuş sayılarının az olmasının sebebi Dünya’da ve ülkemizde yaşanan salgın sürecidir.




Şekil 3.6. Planlanan ve gerçekleşen uçuş sayıları (2020)

2020 yılının aylarına göre gerçekleştirilemeyen uçuş sayıları ve gerçekleştirilememe sebepleri Şekil 3.7’de yer almaktadır. 2019 yılına benzer olarak Ocak ve Şubat aylarında gerçekleştirilemeyen uçuşların büyük bir bölümünü meteorolojik hâdiseler oluşturmaktadır. Kasım ayında uçuşları meteorolojik hâdiselerden sonra etkileyen en önemli faktör ise “diğer” olarak adlandırılan olaylardır. Nisan ve Mayıs ayları içerisinde meteorolojik, arıza ve diğer olayların etkisinden söz etmek mümkün değildir. Çünkü bu aylarda çok az uçuş planlanarak gerçekleştirilmiştir.



Şekil 3.7. Gerçekleştirilemeyen uçuş sayıları ve sebepleri (2020)

2020 yılına ait gerçekleşen uçuş oranları ile meteorolojik hâdiseler, arıza ve diğer olaylardan kaynaklı gerçekleştirilemeyen uçuş oranları Şekil 3.8’de verilmektedir. Gerçekleştirilemeyen uçuşların en büyük sebebinin 2019 yılıyla benzer şekilde meteorolojik hâdiseler olduğu açıkça görülmektedir. Tüm yıl boyunca uçuşların %25’ i meteorolojik hâdiseler kaynaklı olarak yapılamamıştır. Bu oranı %1’er diğer olaylar ve arıza kaynaklı olaylar takip etmektedir. 2019 yılından farklı olarak 2020 yılında uçuşların %25’i meteorolojik nedenlerle gerçekleştirilememiştir.



Şekil 3.8. Gerçekleşen uçuş oranları ile gerçekleştirilemeyen uçuş oranları ve sebepleri (2020)

FTO'lar imkânları dâhilinde insan ve envanter faktörlerini düzenleyebilirler ancak meteorolojik koşulları değiştiremezler ve etkilerine göre hareket etmek zorundadırlar. Bu nedenle uçuşa elverişli günler öncelikli olup, uygulamalı dersler öncelikle uçuşa uygun günler dikkate alınarak planlanmalıdır.

3.3. Bakım Planlamaları ve Diğer

Bakım, uçağın her zaman gerekli performans ve güvenliği sağlayacak konumda, ilk günkü gibi yeni ve iyi çalışır durumda tutulmasıdır [12,34]. Uçaklar yıl boyunca sürekli bir şekilde hizmet verememektedir ve kesintisiz kullanıma uygun değildir. Socata TB-20 ve Cessna 172 SP uçaklarının aylık faaliyet durumu Tablo 3.2'de verilmektedir [29]. Eğitim ve bakım faaliyetleri uçuşa elverişli günlerin analiz edilmesi ışığında daha doğru planlanabilir.

Tablo 3.2. ESTÜ-P envanterindeki uçakların Faal&Gayr-i faal durumu

İlk yıl		Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
Socata	F	22	18	14	18	22	17	17	20	10	-	14	22
TB-20	G	-	2	8	1	-	4	5	-	10	20	7	-
Cessna	F	-	5	21	16	12	19	19	13	18	20	20	11
172SP	G	22	15	1	3	10	2	3	7	2	-	1	11
İkinci yıl		Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
Socata	F	14	18	13	22	10	21	-	-	-	15	21	22
TB-20	G	-	2	9	2	12	-	23	19	18	2	-	-
Cessna	F	9	17	15	24	20	21	-	16	16	17	19	19
172SP	G	5	3	7	-	2	-	23	3	2	-	2	3

Uçuş eğitimlerinin ticarî uçuş yapılan havalimanlarında yapılması uygulamalı eğitimlerin devamlılığını olumsuz yönde etkilemektedir. Ortak kullanılan

havalimanlarında FTO'ların dikkate alması gereken bir diğer konu da ticarî uçakların kalkış ve inişlerinin neden olduğu türbülansın eğitim uçaklarını riske atarak pist kullanımını sınırlandırmasıdır. FTO'lar birçok faktör göz önünde bulundurularak planlarının dinamik ve sürekli olarak güncellendiği eğitim kurumlarıdır.

3.4. Bulgular ve Tartışma

Uçuş eğitim organizasyonlarında sürdürülebilir ve nitelikli bir eğitim sisteminin oluşturabilmesi için en önemli koşul sahip olunan kaynakların etkin kullanılması ve verilecek eğitiminin uluslararası standartları karşılayabilmesidir. Bu vaka çalışması ile, faaliyet göstermekte veya yeni kurulacak olan uçuş eğitim organizasyonlarının verimliliğini etkileyen faktörlerden meteorolojik hâdiseler ve uçuş eğitim organizasyonları üzerindeki etkileri açıklanmaya çalışılmıştır. Çünkü uçuşların planlanması, uçakların bakım zamanları, seyir sürelerinin, hareket rotalarının ve uçuş irtifâsının tespiti gibi birçok konu meteorolojik bilgiler ışığında gerçekleştirilmektedir. Özetle, meteorolojik hâdiseler uçuş faaliyetlerini doğrudan etkilemektedir. Uçuş eğitiminin emniyetli ve ekonomik olabilmesi için meteorolojik hâdiseler ve bu hâdiselerin isabetli tahmin edilmesi oldukça önemlidir. Özellikle uçuş eğitim faaliyetleri açısından düşünüldüğünde meteorolojik hâdiselerin uçuş emniyeti üzerindeki etkisi daha da önemli bir hâl almaktadır. Aşağıda sıralanan maddeler çalışmanın bulgularını ve önemini özetlemektedir:

- 2019 yılında 1.451 uçuş yapılabilmişken 1.233 uçuş meteoroloji kaynaklı mücbir sebeplerle gerçekleştirilememiştir. Diğer bir ifade ile uçuşların %45'i meteorolojik gerekçelerle iptal edilmiştir. 30 uçuş arıza ve 52 uçuş ise diğer faktörlerden dolayı yapılamamıştır.
- 2020 yılında meteoroloji kaynaklı iptal edilen uçuş sayısının 2019 yılına göre daha az olduğu görülmektedir. Toplamda 2.840 uçuş gerçekleştirilebilirken 959 uçuş meteorolojik hâdiselerce engellenmiştir. Meteorolojik hâdiseler nedeniyle gerçekleştirilemeyen uçuşlar toplam uçuşların %25'ini oluşturmaktadır. 2020 yılında 2019 yılına kıyasla arıza nedeniyle gerçekleştirilemeyen uçuş sayıları daha fazladır. 43 uçuş arıza nedeniyle ve 45 uçuş ise diğer faktörlerden dolayı yapılamamıştır.
- 2019 ve 2020 yıllarında toplam 4.291 uçuş gerçekleştirilebilmiştir. Meteoroloji, arıza ve diğer gerekçelerinin sebep olduğu gerçekleştirilemeyen uçuş sayıları

sırasıyla 2.192, 73 ve 97 şeklindedir. Meteorolojik hâdiseler nedeniyle gerçekleştirilemeyen uçuşlar iki yıl için toplam %33 oranındadır.

Bu bulgular ışığında, meteorolojik hâdiselerin uçuş eğitimini önemli ölçüde etkilediği belirlenmiştir. Uçuş eğitiminin yaklaşık 3'te 1'inin meteorolojik hâdiseler sebebiyle yapılamadığı görülmektedir. Bu sonucun uçuş eğitim organizasyonunun verimliliğini doğal olarak olumsuz bir şekilde etkilediği tespit edilmiştir. Diğer bir ifadeyle ESTÜ-P'de meteorolojik hâdiseler nedeniyle gerçekleştirilemeyen uçuşlar, eğitmen pilotların ve teorik bilgi öğretmenlerinin iş yükünün artmasına, uçuş eğitimi için ayrılan sürenin uzamasına, bakım ve onarım faaliyetlerine ayrılan sürenin artmasına, uçuş emniyetinin dolaylı olarak azalmasına, çevresel ve ekonomik problemlerin oluşmasına sebebiyet vermektedir. Bu sonuçlar göstermiştir ki, bir uçuş eğitim organizasyonunda meteorolojik hâdiseler nedeniyle uçuşların büyük bir bölümü yapılamamaktadır. Bu nedenle kurulacak olan veya kurulmuş olan uçuş eğitim organizasyonlarının uçuş yapacakları bölgenin meteorolojik özelliklerini detaylı bir şekilde incelemeleri, uçuşa elverişli gün sayısını hesaplayarak değerlendirmeleri gerekmektedir. Hatta gerekirse müsait başka bölgelerde uçuş planlamaları veya pratik ders hizmet alımı planlamaları yapmaları gerekmektedir.

4. UÇUŞA ELVERİŞLİLİK VE ZAMAN SERİSİ


Sivil Havacılık Genel Müdürlüğü (SHGM), Türkiye'de havacılık otoritesi olarak hizmet vermekte ve FTO'ları yönetmelikler nezdinde denetlemektedir. Türkiye havacılık mevzuatı, Uluslararası Sivil Havacılık Örgütü (ICAO, International Civil Aviation Organization) ve Avrupa Havacılık Emniyeti Ajansı (EASA, European Aviation Safety Agency) tarafından yayınlanan uluslararası kılavuzlara göre hazırlanmaktadır. FTO'larda pilot eğitimleri, ulusal ve uluslararası düzenlemelere uygun olarak gerçekleştirilmektedir [29,118]. ICAO Annex 3'te belirtildiği üzere, meteoroloji odaklı havacılık araştırmalarının en az 5 yılı kapsayan bir gözlem sonucunda elde edilmiş verilerle yapılması gerektiği belirtilmektedir [119]. Bu çalışmada Ocak 09' – Aralık 20'ı kapsayan 12 yıllık bir zaman diliminde saat ölçekli METAR verileri kullanılarak ilgili gereklilik fazlaca karşılanmaktadır. Böylece, 102.920 adet METAR tablosu kullanılarak 4.382 elemanlı bir uçuşa elverişlilik zaman serisi (UEZS) oluşturulmuştur. METAR verileri, eğitim uçağının kullanım kılavuzunda yer alan teknik kısıtlamalar, SHGM tarafından VFR operasyonların gerçekleştirilebilmesi için belirlenen yasal kısıtlamalar ve

yönetmeliklerle belirlenmemiş ancak FTO tecrübelerine dayalı ve dikkate alınması gereken kısıtlamalar açısından değerlendirilmiştir [2,29–31,38]. Böylece gün içinde uçuşlara uygun saatler tespit edilmiş ve zaman serileri ile ifade edilmiştir. Bu kısıtlamalar sırasıyla sunulacaktır.

4.1. Teknik Limitler

Havalimanları, yolcu ve yüklerin bir varış noktasına taşındığı ve katlanarak artan pilot ihtiyacını karşılamak için yoğun uçuş eğitimlerinin yapıldığı alanlardır. Uçaklar operasyonlar sırasında pist doğrultusunda iniş ve kalkışlarını gerçekleştirmektedirler [120]. Buna göre eğitim uçağı, Tablo 3.1 ve Ek-1’de yer alan havalimanı meydan krokisinde görüldüğü 09/27 pisti yönünde iniş ve kalkışlarını yapmak zorundadır [118].

Bir FTO'nun başlıca fiziksel kaynağı uçaktır ve eğitimde kullanılacak bir uçağın özellikleri ulusal ve uluslararası düzenlemelerle belirlenmektedir. Uçaklar, tasarımlarına göre farklı ağırlıklarda ve farklı aerodinamik özelliklerde üretilmektedirler. Uçuş emniyetini tehlikeye atan yan rüzgâr limitleri, üreticiler tarafından kılavuzlarda belirtilmiştir. ESTÜ-P envanterinde yer alan Cessna 172 SP ve Socata TB-20 uçaklarının yan rüzgâr limitleri ve baş/kuyruk yan rüzgâr bileşeninin açıya bağlı değişimi Şekil 4.1’de verilmektedir. METAR tablolarında yer alan rüzgâr verileri çizelgeye göre değerlendirilerek yan rüzgârların iniş ve kalkışlarında uçuş emniyetini tehlikeye sokup sokmadığı değerlendirilmiştir. Çizelgeye göre Cessna 172 SP için 15 kt, Socata TB-20 için 25 kt yan rüzgâr limiti dâhilinde uçaklar emniyetli uçuş operasyonları gerçekleştirebilmektedirler [121,122].




Şekil 4.1. Cessna 172 SP ve Socata TB-20 uçakları için yan rüzgâr limit çizelgesi

4.2. Düzenlemeler

Meteorolojik hâdiseler, alçak irtifâlarda gerçekleştirildiği vakit uçuş eğitimini sıklıkla etkilemektedir. Devlet Hava Meydanları İşletmesi (DHMİ) Genel Müdürlüğü tarafından yayınlanan Türk Havacılık Enformasyon Yayını'nda (AIP, Aeronautical Information Publication) VFR uçuşların yapılabileceği koşullar düzenlenmektedir. VFR uçuş operasyonları ancak mevzuatta yer alan şartlar sağlandığında gerçekleştirilebilmektedir. Buna göre, VFR uçuş operasyonunun gerçekleştirilebilmesi; rüyetin 5 km'nin üzerinde olması, bulut tavanının 1.500 ft'in üstünde olması ve gün doğumundan yarım saat önce ile gün batımından yarım saat sonra arasındaki süreç içerisinde operasyonun gerçekleştiriliyor olması halinde mümkündür [118]. Dünyanın eksen eğikliği ve yıllık hareketi sonucunda gün doğumu ve gün batımı saatleri yani güneşlenme süreleri yıl boyunca sürekli değişmektedir. Dolayısıyla gün içerisindeki gün doğumu ve gün batımı saatleri yıl boyunca sabit değildir. Şekil 4.2'de yıl içinde enlemlere göre güneşlenme süreleri verilmekte ve çalışmaya konu olan LTBY için izhâr edilmektedir. Rüyet ve bulut tavan yüksekliği şartları METAR tablolarında yer

almaktadır ancak uçuşun yapılabileceği sürenin saptanması için gün doğumu ve gün batımı saatleri hesaplanmalıdır[123]. Çalışma kapsamında METAR rasatları VFR uçuş için uygun yasal süreler içerisinde bulunup bulunmamları açısından da değerlendirilmektedir.



Şekil 4.2. LTB Y'nin yıl içerisinde gündüz süreleri

4.3. Uzman Görüşü

Uçuşa elverişli günler mevzuatlarla belirlenmemiştir. Uçuş eğitmeni pilotların deneyimlerine göre meteorolojik koşulların uygun olup olmadığının belirlenmesi için bazı tecrübî kriterler kullanılmaktadır [38]. Deneyimsiz pilot adayları açısından Bölüm 2'de gerekçeleri sunulan meteorolojik hâdiseler ve eğitim uçağının limitleri göz önünde bulundurularak, ESTÜ-P'de uçuş emniyetinin geliştirilebilmesi için uygulamalı dersler aşağıdaki kriterler göz önünde bulundurularak gerçekleştirilmektedir:

- Bulut kapallılığı 5/8 oktadan az olmalıdır
- Bulut tabanı 3.000 ft'den fazla olmalıdır
- Buzlanma durumu olmamalı ve sıcaklık 5°C'den az ve 25°C'den fazla olmamalıdır.
- Gök gürültülü sağanak yağışlar, şiddetli sağanak yağışlar, kümülüs kongestus bulutları ve kümülönimbus bulutları olmamalıdır.

5. YÖNTEM

Bu bölümde tahmin çalışmasında kullanılan yöntemler tanıtılmaktadır. Bu maksatla bir zaman serisinin ayrıştırılarak alt zaman serileri toplamı formunda ifade edilmesine olanak sağlayan ayrıştırma (decomposition) yöntemleri ve girdi-çıkı ilişkisi kurarak tahmin sonuçları üreten derin öğrenme yapıları incelenmektedir.

5.1. Sinyal Ayrıştırma Yöntemleri


Ayrıştırma, zaman serisinin içeriğinden alt zaman serileri çıkarılmasına dayanan bir veri analiz yöntemidir. Çıkarılan alt zaman serileri toplamı ham zaman serisini oluşturacak şekilde ayrıştırma yapılmaktadır. Ayrıştırma işlemi bazı alt zaman serilerinin kullanılmak üzere seçilmesine imkân tanınması nedeniyle bir filtre olarak kullanılabilir. Fourier spektral analizinde sistemin lineer olduğu ve verilerin kesin durağan (strictly stationary) veya periyodik olduğu varsayılır. Gereksinimler karşılanmazsa, ortaya çıkan spektrum zayıf bir fiziksel karşılık sunacaktır. EMD ve VMD yöntemleri, doğrusal olmayan ve durağan olmayan verileri analiz etme yeteneğine sahiptir [124,125]. Enerji-zaman-frekans gösterimi olan analiz yetenekleri ve doğrusal olmama (non-linear), durağan olmama (non-stationary) durumunu uyarlanabilir bir yaklaşımla ele almaları nedeniyle çalışmada tercih edilmişlerdir. Modelde EMD veya VMD yöntemlerinden yararlanılması, özellikle bu çalışmada olduğu gibi görece yüksek varyanslı zaman serilerinde, yalnız ham zaman serilerinin kullanılmasına kıyasla tahmin doğruluğunu artırabilmektedir.

5.1.1. Empirical mode decomposition (EMD)


EMD, zaman serilerini IMF (Intrinsic Mode Function) şeklinde isimlendirilmiş alt zaman serilerine ayırmak için kullanılan durağan olmayan zaman serileri için kullanılabilen ve doğrusal olmayan bir analitik araçtır. Özyinelemeli (recursive) bir yöntem olması nedeniyle bir IMF ayrıştırıldıktan sonra kalandan bir diğer IMF'in elde edilmesi mümkün olmaktadır. IMF'ler, ham zaman serisinden kaydırma (shifting) olarak bilinen bir dizi işlemle elde edilmektedirler. IMF'lerin iki kısıtı karşılaması gerekmektedir. Yerel maksimumların ve yerel minimumların oluşturduğu enterpolasyon zarflarının ortalama değerleri her noktada sıfır olmalıdır. Tüm veri katarındaki ekstremum ve sıfır geçiş sayısı, eşdeğer olmalı veya birden fazla olmamalıdır. Kısıtlar tamamlanıncaya kadar eleme işlemine devam edilmektedir. Buna göre, kaydırma adı verilen işlem prosedürleri şu şekildedir:

1. Zaman serisinin $\zeta(\cdot)$ lokal maksima ve minima noktalarının belirlenmesi
2. Lokal maksima noktaları $E_{üst}(t)$ ve lokal minima noktaları $E_{alt}(t)$ arasında enterpolasyon yaparak zarflarının belirlenmesi
3. Üst ve alt zarflar arasında $\mu(t) = \frac{E_{üst}(t) + E_{alt}(t)}{2}$ ortalamanın bulunması
4. Zaman serisinden ortalamanın çıkarılması $d(t) = \zeta(t) - \mu(t)$
5. Fark serisi $d(t)$ 'nin ilk adımdan itibaren yeni bir IMF olarak yeniden işlenmesi

Ham zaman serisi, kaydırma adımlarını yinelemeli tekrarlayarak alt zaman serilerine ayrıştırılmaktadır. IMF'lerin simetrik zarflara sahip olduğuna, standart sapma $\sigma(\cdot)$ değerlendirilerek karar verilmekte ve 0,2 ile 0,3 arasında bir değerin uygun olduğu düşünülmektedir. Yine daha küçük değerler için $\sigma(\cdot)$ uygun kabul edilmektedir. Şekil 5.1'de EMD yönteminde ayrıştırma işlem basamakları gösterilmektedir.



Şekil 5.1. EMD ayrıştırma akış diyagramı



Şekil 5.3. Pchip interpolasyonlu EMD ayırıştırma örneği

Çalışmada spline ve pchip interpolasyonunu kullanma ve inceleme motivasyonu, UEZS'nin akıcı olmaması nedeniyle bu interpolasyonların ayrıca alternatif filtreler olarak kullanılabilmesidir.

5.1.2. Variational mode decomposition (VMD)

VMD, zaman serisinin frekans merkezini özyinelemesiz (non-recursive) ve uyarlamalı olarak belirleyen bir yarı ortogonal (quasi-orthogonal) sinyal ayırıştırma yöntemidir. EMD'den farklı olarak zaman serisinin belirlenen sayıda alt zaman serisine aynı anda ayırıştırması söz konusudur. Yine, EMD'den farklı olarak çözümü bir varyasyon problemi olarak ele almaktadır. Varyasyon problemi Wiener filtre, Fourier Dönüşümü, Hilbert dönüşümü ve frekans çarpma yöntemleriyle çözülmektedir. VMD, mükemmel gürültü filtreleme özelliklerine sahiptir ve sınırlı bir bant genişliğinde temel frekansların tonlarını algılayabilir. Böylelikle gürültünün tahmin performansı üzerindeki olumsuz etkisinin azaltılmasına imkân tanımaktadır [124,130,131].

VMD yöntemi ilk olarak 2014 yılında Dragomiretskiy ve Zosso tarafından literatüre sunulmuştur. Yöntem, zaman serisinin $\varsigma(\cdot)$, (5.1)'deki genlik&frekans modülasyon (AM-FM) sinyali olan IMF'ler $u_k(\cdot)$ toplamı olduğunu varsayar.

$$\varsigma(t) = \sum_k u_k(t) = \sum_k A_k(t) \cos(\phi_k(t)) \quad (5.1)$$

Burada $A_k(t)$ ve $\phi_k(t)$, sırasıyla $u_k(t)$ 'nin zarfı ve fazıdır. Faz $\phi_k(t)$ azalmayan bir fonksiyon olduğundan, anlık frekans $\phi'_k(t) \geq 0$ ve hem $A_k(t)$ hem de $\omega_k(t)$ fazdan daha yavaş değişir. Başka bir bakış açısıyla, $[t - \delta, t + \delta]$ yeterince uzun bir aralık ($\delta \approx \frac{2\pi}{\phi'_k(t)}$) için IMF'in $A_k(t)$ genlikli ve $\phi'_k(t)$ anlık frekanslı bir saf harmonik sinyal olduğu düşünülebilir.

VMD, bir kısıtlı varyasyon modeli oluşturarak ayrıştırma problemini varyasyon problemine dönüştürmektedir. Modal fonksiyon $u_k(t)$ ve kök frekansı ω_k , yinelemeli (iterative) bir şekilde en uygun çözümü bulmak üzere güncellenir. Son olarak, ters Fourier dönüşümü kullanılarak, zaman alanında (domain) IMF'ler türetilmektedir. IMF, ω_k civarında sınırlı bir bant genişliğine sahip olduğundan varyasyon probleminin çözümü ile modal fonksiyonların çözümü gerçekleştirilir.

Fourier dönüşümü $\mathcal{F}[\cdot]$ sinyallerin frekans bileşenlerini elde etmek için kullanılmaktadır. Sinyalin Fourier dönüşümünü alındığında, spektrumda hermitian simetriye sahip yani aynı magnitüd ve farklı işaretli frekans nicelikleri elde edilmektedir. Denklem 5.2'de açısal frekans üniter (unitary) form ($\frac{1}{\sqrt{2\pi}}$ çarpanına sahip) Fourier dönüşümü, (5.3)'de ise işlemlerin son basamağında modal fonksiyonların türetilmesinde kullanılan ters Fourier dönüşümü yer almaktadır [132].

$$\hat{\zeta}(\omega) = \mathcal{F}[\zeta(t)] \triangleq \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \zeta(t) e^{-j\omega t} dt \quad (5.2)$$

$$\zeta(t) = \mathcal{F}^{-1}[\hat{\zeta}(\omega)] \triangleq \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \hat{\zeta}(\omega) e^{j\omega t} d\omega \quad (5.3)$$

Sinyallerin ayrılması için kullanılan diğer bir yöntem, Denis Gabor'un, faz seçiciliğine dayanan ve sinyaller arasındaki faz kaymalarını kullanan Hilbert dönüşümü $\mathcal{H}[\cdot]$ yöntemidir. Bir sinyalin tüm bileşenlerinin faz açıları 90 derece kaydırıldığında elde edilen zaman fonksiyonu, sinyalin Hilbert dönüşümü olarak bilinir. Spektral bileşenlerin fazlarının $\frac{-\pi}{2}$ ile kaydırıldığı ancak genliklerin aynı bırakıldığı tam geçişli bir filtredir [133]. Başka bir deyişle, (5.4)'de verilen $\mathcal{H}[\cdot]$, kosinüs fonksiyonlarını karşılık gelen sinüs fonksiyonlarına dönüştürmektedir. Tekillik $t = \tau$ için mümkün olduğundan, evrişim integrali bir Cauchy ana değeri'ne (principal value) sahiptir.

$$\tilde{\zeta}(t) = \mathcal{H}[\zeta(t)] \triangleq \frac{1}{\pi} p. v. \int_{\mathbb{R}} \frac{\zeta(\tau)}{t - \tau} d\tau \quad (5.4)$$

Denklem 5.4'teki tanımdan Hilbert dönüşümü, $\zeta(t)$ ve $\frac{1}{\pi t}$ zaman fonksiyonunun evrişimine (convolution) eşittir. Zaman alanındaki iki fonksiyonun evrişimi $\star$, frekans alanındaki Fourier dönüşümlerinin çarpımına eşittir. $\frac{1}{\pi t}$ 'nin Fourier dönüşümü $\mathcal{F}\left[\frac{1}{\pi t}\right] = -j\text{sgn}(\omega)$ olduğundan, Hilbert dönüşümü frekans alanında (5.5)'de verildiği üzere bir çarpma işlemidir [132].


$$\hat{\zeta}(\omega) = \mathcal{F}[\zeta(t)] \Rightarrow \mathcal{H}[\hat{\zeta}(\omega)] = -j\text{sgn}(\omega)\hat{\zeta}(\omega) \quad (5.5)$$

Analitik sinyal ζ_A , (5.6)'da verilen Euler formülünün, (5.7)'teki gibi karmaşık fonksiyon formunda genelleştirilmesidir; burada $\tilde{\zeta}(t)$, $\zeta(t)$ 'nin karmaşık eşlenik (quadrature) fonksiyonudur.

$$e^{j\phi(t)} = \cos(\phi(t)) + j\sin(\phi(t)) \quad (5.6)$$

$$\zeta_A(t) = \zeta(t) + j\tilde{\zeta}(t) = |\zeta_A(t)|e^{j\phi(t)} \quad (5.7)$$

Burada, karmaşık üstel terim $e^{j\phi(t)}$ karmaşık sinyalin zaman içindeki dönüşünü ifade eden fazör, $\phi(t)$ faz, $|\zeta_A(t)|$ ise genliktir. Şekil 5.4'te kutupsal düzlemde (5.7) için örnek görsel verilmektedir.



Şekil 5.4. Kutupsal düzlemde analitik sinyal gösterimi

Analitik sinyal pozitif frekanslarda ve eşlenik analitik sinyal negatif frekanslarda tek taraflı (unilateral) bir spektruma sahiptir. Analitik sinyalin, gerçel kısmını alarak $\zeta(t) = \Re\{\zeta_A(t)\}$ başlangıç sinyaline ulaşılabilir. Hilbert dönüşümü vasıtasıyla, başlangıç sinyalden anlık genlik (zarf, magnitüd), anlık faz ve anlık frekans hakkında bazı ek bilgiler elde etmek mümkündür.

Varyasyon probleminin yapılandırılması üzere tek taraflı frekans spektrumu ve analitik sinyal elde etmek için, $\mathcal{F}[\delta(t)] = 1$ ve $\zeta(t) \star \delta(t) = \zeta(t)$ özelliklerine sahip (5.8)'de verilen dirac-delta fonksiyonu kullanılarak (5.9)'daki gibi her u_k için Hilbert dönüşümü yapılır.

$$\delta(t) = \begin{cases} 0, & t \neq 0 \\ \int \delta(t) dt = 1, & t = 0 \end{cases} \quad (5.8)$$

$$\left[\delta(t) - \frac{j}{\pi t} \right] \star u_k(t) \quad (5.9)$$

Denklem 5.7'de yer aldığı üzere analitik sinyalin üstel bir kısmı bulunmaktadır. Bu nedenle $e^{j\omega_1 t} e^{j\omega_2 t} = e^{j(\omega_1 + \omega_2)t}$ olduğundan Fourier dönüşümlerinde (5.10) şeklinde tanımlanabilir.

$$\zeta_A(t) e^{-j\omega_0 t} \xleftrightarrow{\mathcal{F}} \hat{\zeta}_A(\omega) \star \delta(\omega + \omega_0) = \hat{\zeta}_A(\omega + \omega_0) \quad (5.10)$$

Denklem 5.11'de verilen çarpma işlemi ile her u_k 'yi ilgili temel frekans bandına modüle etmek mümkündür.

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) \star u_k(t) \right] e^{-j\omega_k t} \quad (5.11)$$

Her bir u_k 'nin bant genişliği gradyanın L^2 -normunun (Euclidean norm) karesi kısıtlı ifadesinden çözülmektedir.

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \star u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \ni \sum_k u_k = \zeta(t) \quad (5.12)$$

Burada ∂_t zaman türevidir, u_k ise $\zeta(t)$ 'nin sınırlı bant genişliğindeki modal fonksiyonlarıdır ve ω_k karşılık gelen merkez frekanslarıdır. Kısıtlı problem, Langrange çarpanları λ ve ikinci dereceden bir ceza terimi α kullanılarak kısıtsız varyasyon

problemine dönüştürülür ve böylece yinelemeli olarak çözülebilir hale getirilmektedir. Augmented Lagrangian $\mathcal{L}$ metodu, (5.13)'de verilmiştir.

$$\begin{aligned} \mathcal{L}(\{u_k\}, \{\omega_k\}, \lambda) \triangleq & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \star u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ & + \left\| \varsigma(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), \varsigma(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (5.13)$$

Böylelikle problem, Alternate Direction Method of Multipliers (ADMM) algoritması ile çözülebilir hale gelmektedir ve ham zaman serisi IMF'lere ayrıştırılabilmektedir [124,134,135]. Denklem 5.17'de verilen kriter sağlanana kadar, $\hat{u}_k$ ve ω_k sırasıyla (5.14) ve (5.15) ile iç döngüde ve ayrıca $\hat{\lambda}_k$ (5.16) ile yinelemeli olarak güncellenmektedir.


$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{\varsigma}(\omega) - \sum_{i \leq k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (5.14)$$

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (5.15)$$


$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau(\hat{\varsigma}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (5.16)$$

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (5.17)$$

Burada; n , belirlenmiş maksimum değeriye kadar yineleme sayısı, τ Langrange çarpanı için zaman adımı parametresi ve ε , sıfırdan büyük ve sıfıra yakın değerli yakınsama toleransı kriteridir. Şekil 5.5'te UEZS'nin bir senelik sürecine ilişkin VMD ayrıştırma örnek görseli ve (5.6)'da ise VMD yöntemi ayrıştırma işlem basamakları verilmektedir.



Şekil 5.5. VMD ayrıştırma akış diyagramı




Şekil 5.6. VMD ayrıştırma örneği

5.2. Recurrent Neural Network (RNN)

RNN modellerinde, önceki zamana ait gizli katman çıktısı, zaman dizisindeki girdi ile birlikte bir sonraki zaman çıktıları elde etmek üzere girdi olarak sıralı bir şekilde kullanılmaktadır. Böylece geçmiş bilgiler ağı aktarılabilir ve ağ mevcut tahmin eğilimini de bir girdi olarak kullanarak önceki bilgilerle beraber bir tahmin yapabilir. GRU sinir ağları ve LSTM sinir ağlarının her ikisi de kendi hücre modellerine sahip birer RNN yapılarıdır [63,102,136,137]. Geleneksel RNN'ler kaybolan (vanishing) ve patlayan (exploding) gradyan problemlerinden muzdariptirler, bu nedenle öğrenme ağıdaki zaman akışıyla birlikte azalmaktadır. LSTM ve GRU ağları, bilginin zaman içinde geçtiği Cell State (Hücre Durumu) ve Hidden State (Gizli Durum) mekanizmalarını kullanarak bu sorunların üstesinden gelebilmekte ve uzun vade bağımlı bilgiden faydalanabilmektedirler. Bu ağlarda bilgi akış kontrolü, kapı mekanizmaları kullanılarak gerçekleştirilmektedir. LSTM'nin Unut (Forget), Giriş (Input) ve Çıkış (Output) Kapıları (Gate) olmak üzere üç kapı mekanizması bulunmaktadır. GRU, Unut ve Giriş Kapılarının işlevini birleştirmek suretiyle oluşturulan Güncelleme (Update) Kapı mekanizmasına sahiptir. Böylelikle LSTM'den daha az parametresi vardır ve daha az karmaşıklıktadır. Kısaca, LSTM'nin basitleştirilmiş bir çeşididir.

5.2.1. Long short-term memory (LSTM)

LSTM'in ilk sürümü, Sepp Hochreiter ve Jürgen Schmidhuber tarafından CEC (Constant Error Carousel) yapısının sabit hata akışına izin veren bir mimariyi oluşturan ek özelliklerle donatılması ile 1997 yılında literatüre sunulmuştur. LSTM modelinin GRU modelinden farklı olarak Giriş Kapısı, Çıkış Kapısı ve Unut Kapısı olmak üzere üç kapısı bulunmaktadır. Unut Kapısı önceki zaman adımlarının akış üzerinde etkinliğini düzenlemekte, Giriş Kapısı akışa destekleri yönetmekte ve Çıkış Kapısı ağı geri kalanına bilgi akışını sağlamaktadır. GRU'ya göre daha karmaşık işlemler gerektirse de bazen daha iyi sonuçlar üretebilir. Çalışmada kullanılan geleneksel LSTM hücre modeli Şekil 5.7'de sunulmuştur.



Şekil 5.7. LSTM hücre yapısı

LSTM hücre modeli denklemleri (5.16)'dan (5.21)'e kadar verilmiştir. Eğitim, zaman sıralı LSTM hücrelerinden oluşan RNN'deki gradyan problemini çözmektir.

$$\mathbf{I} = \sigma(\mathbf{XW}_{ii} + \mathbf{b}_{ii} + \mathbf{HW}_{hi} + \mathbf{b}_{hi}) \quad (5.16)$$

$$\mathbf{F} = \sigma(\mathbf{XW}_{if} + \mathbf{b}_{if} + \mathbf{HW}_{hf} + \mathbf{b}_{hf}) \quad (5.17)$$

$$\mathbf{G} = \tau_h(\mathbf{XW}_{ig} + \mathbf{b}_{ig} + \mathbf{HW}_{hg} + \mathbf{b}_{hg}) \quad (5.18)$$

$$\mathbf{O} = \sigma(\mathbf{XW}_{io} + \mathbf{b}_{io} + \mathbf{HW}_{ho} + \mathbf{b}_{ho}) \quad (5.19)$$

$$\mathbf{C}' = \mathbf{F} \odot \mathbf{C} + \mathbf{I} \odot \mathbf{G} \quad (5.20)$$


$$\mathbf{H}' = \mathbf{O} \odot \tau_h(\mathbf{C}') \quad (5.21)$$

Burada üst simge $\mathfrak{m}$ örnek sayısı (batch), $\mathfrak{x}$ girdi ve $\mathfrak{h}$ ise gizli katman sayısı olmak üzere; $\mathbf{X} \in \mathbb{R}^{\mathfrak{m} \times \mathfrak{x}}$, $\mathbf{C}, \mathbf{C}' \in \mathbb{R}^{\mathfrak{m} \times \mathfrak{h}}$, $\mathbf{I}, \mathbf{F}, \mathbf{O} \in (0,1)^{\mathfrak{m} \times \mathfrak{h}}$, $\mathbf{G}, \mathbf{H}, \mathbf{H}' \in (-1,1)^{\mathfrak{m} \times \mathfrak{h}}$, $\mathbf{b} \in \mathbb{R}^{1 \times \mathfrak{h}}$, $\mathbf{W}_{ii}, \mathbf{W}_{if}, \mathbf{W}_{ig}, \mathbf{W}_{io} \in \mathbb{R}^{\mathfrak{x} \times \mathfrak{h}}$, $\mathbf{W}_{hi}, \mathbf{W}_{hf}, \mathbf{W}_{hg}, \mathbf{W}_{ho} \in \mathbb{R}^{\mathfrak{h} \times \mathfrak{h}}$, $\odot$ operatörü Hadamard çarpımı, $\sigma(\cdot)$ sigmoid fonksiyonu, $\tau_h(\cdot)$ hiperbolik tanjant fonksiyonunu, $\mathbf{W}$ ağırlıkları ve $\mathbf{b}$ bias'ı ifade eder. Giriş Kapısı (5.16), Unut Kapısı (5.17), Hücre Güncelleme (Cell Update) (5.18), Çıkış Kapısı (5.19), Hücre Durumu (5.20) ve Gizli Durum (5.21) kullanılarak hesaplanmaktadır. Sigmoid fonksiyonu nedeniyle, Giriş, Unut ve Çıkış Kapıları (0, 1) aralığındadır. Tanjant hiperbolik fonksiyonun sınırları nedeniyle, Hücre Güncelleme ve Gizli Durum (-1, 1) aralığındadır. Gizli Durum, çıktı katmanına geçirilmektedir. Ayrıca, Hücre Durumu (-1, 1) aralığındadır. Denklem 5.17 ile eski Hücre Durumu içeriğinin ne kadarının elde tutulacağı ve Giriş Kapısı'nın sunduğu yeni verilerin

(5.18) yoluyla hücre içerisinde ne düzeyde ele alınacağı düzenlenmektedir. Hücre Durumu tasarımı kaybolan gradyan problemine çözüm sunmakla beraber uzun vade bağımlı bilgilerden yararlanılabilmesine imkân sağlamıştır. LSTM hücresinde Gizli Durum ve Hücre Durumu akışları hücre çıktısı olarak yer almaktadır. Çıktı katmanına yalnızca Gizli Durum iletilmekle beraber Hücre Durumu yalnızca dâhilî hücre içeriğinin aktarılmasında kullanılmaktadır [137–141].

5.2.2. Gated recurrent unit (GRU)

GRU, RNN’lerde kaybolan gradyan probleminin üstesinden gelebilmek amacıyla Cho ve ark. tarafından tasarlanarak 2014 yılında literatüre sunulmuştur. GRU modelinin, yalnızca bir Güncelleme Kapı ve bir Sıfırlama Kapı (Reset Gate) mekanizmasının bulunması ile LSTM modelinin basitleştirilmiş bir çeşidi olduğu düşünülebilir. GRU Modeli, LSTM Modeline kıyasla daha az hesaplama ihtiyacı duyar ve nispeten az sayıda parametresi bulunması nedeniyle daha hızlı yakınsama kabiliyetine sahiptir. Çalışmada kullanılan geleneksel GRU hücre modeli Şekil 5.8’de sunulmuştur.



Şekil 5.8. GRU hücre yapısı

GRU hücre modeli denklemleri (5.22)’dan (5.25)’e kadar verilmiştir. Benzer şekilde eğitim, zaman sıralı GRU hücrelerinden oluşan RNN’deki gradyan problemini çözmektir.

$$\mathbf{R} = \sigma(\mathbf{XW}_{ir} + \mathbf{b}_{ir} + \mathbf{HW}_{hr} + \mathbf{b}_{hr}) \quad (5.22)$$

$$\mathbf{Z} = \sigma(\mathbf{XW}_{iz} + \mathbf{b}_{iz} + \mathbf{HW}_{hz} + \mathbf{b}_{hz}) \quad (5.23)$$

$$\mathbf{N} = \tau_h(\mathbf{XW}_{in} + \mathbf{b}_{in} + \mathbf{R} \odot (\mathbf{HW}_{hn} + \mathbf{b}_{hn})) \quad (5.24)$$

$$\mathbf{H}' = (1 - \mathbf{Z}) \odot \mathbf{N} + \mathbf{Z} \odot \mathbf{H} \quad (5.25)$$

Burada üst simge $\mathfrak{m}$ örnek sayısı, $\mathfrak{x}$ girdi ve $\mathfrak{h}$ ise gizli katman sayısı olmak üzere; $\mathbf{X} \in \mathbb{R}^{\mathfrak{m} \times \mathfrak{x}}$, $\mathbf{R}, \mathbf{Z} \in (0,1)^{\mathfrak{m} \times \mathfrak{h}}$, $\mathbf{N} \in (-1,1)^{\mathfrak{m} \times \mathfrak{h}}$, $\mathbf{H}, \mathbf{H}' \in \mathbb{R}^{\mathfrak{m} \times \mathfrak{h}}$, $\mathbf{b} \in \mathbb{R}^{1 \times \mathfrak{h}}$, $\mathbf{W}_{ir}, \mathbf{W}_{iz}, \mathbf{W}_{in} \in \mathbb{R}^{\mathfrak{x} \times \mathfrak{h}}$, $\mathbf{W}_{hr}, \mathbf{W}_{hz}, \mathbf{W}_{hn} \in \mathbb{R}^{\mathfrak{h} \times \mathfrak{h}}$, $\odot$ operatörü Hadamard çarpımı, $\sigma(\cdot)$ sigmoid fonksiyonu, $\tau_h(\cdot)$ hiperbolik tanjant fonksiyonunu $\mathbf{W}$ ağırlıkları ve $\mathbf{b}$ bias'ı ifade eder. Sıfırlama Kapısı (5.22), Güncelleme Kapısı (5.23), Aday Gizli Durum (Candidate Hidden State) (5.24) ve Gizli Durum (5.25) kullanılarak hesaplanmaktadır. Sigmoid fonksiyonu nedeniyle Reset Gate ve Update Gate (0, 1) aralığındadır. Tanjant hiperbolik fonksiyonun sınırları nedeniyle, Aday Gizli Durum (-1, 1) aralığındadır. Gizli Durum, yine (-1, 1) aralığında olan çıktı katmanına geçirilir. Denklem 5.22 önceki Gizli Durum'un ne düzeyde kullanılacağını söz gelimi hatırlanacağını kontrol edilmesini, (5.23) ise yeni Gizli Durum oluşturulmasında önceki durumun ne düzeyde aktarılacağını düzenlemektedir. Denklem 5.25'de yer aldığı üzere $\mathbf{Z}$ 'nin 1 olmasıyla Gizli Durum eskinin bir kopyası iken 0 olmasıyla Aday Gizli Durum'un kopyası olmaktadır. Akış üzerinde Sıfırlama Kapısı kısa, Güncelleme Kapısı ise uzun vade bağımlılıkların yakalanması görevlerini üstlenmişlerdir. Böylelikle, kaybolan gradyan problemi azaltılarak uzun vade bağımlılıklarının yakalanması olanaklı hâle gelmiş olmaktadır [138,139,142,143].

6. DEĞERLENDİRME

Bu bölümde modellerin eğitimleri boyunca ve test modellerinin değerlendirilmesinde kullanılan performans ölçütleri ve bu ölçütlerin temel modellerle kıyaslanmasında kullanılan iyileştirme analizi tanıtılmaktadır. Modellerin farklı mevsimsel örüntülerde performanslarının ortaya konulması üzere ay bazında yapılan değerlendirmelere Sonuçlar Bölümü'nde yer verilmiştir.

6.1. Performans Ölçütleri

Açık literatürde çeşitli değerlendirme ölçütleri bulunmaktadır. Bölüm 1.3'de açık literatürde kullanılan performans ölçütleri yayın nezdinde özetlenmiştir. Benzer çalışmalarda sıklıkla kullanılması ve hata biriminin çalışma veri seti birimiyle aynı birimde sonuçlar üretmesi bakımından Ortalama Karekök Hatası (RMSE, Root-Mean-Square Error) ve Ortalama Mutlak Hata (MAE, Mean Absolute Error) tez çalışması kapsamına alınmaktadır. Yine açık literatürde sıklıkla yer alan MSE doğal olarak

hesaplanmış olmaktadır fakat birim kare sonuçları nedeniyle araştırmalar kapsamında özellikle belirtmeye değer bulunmamıştır. Ölçekten bağımsız yüzde ifadeler içeren Ortalama Mutlak Yüzde Hata (MAPE, Mean Absolute Percentage Error) ölçütünün açık literatürde sıklıkla yer bulduğu görülmektedir. Fakat gözlem değerleri sıfır olduğunda veya sıfıra yakın olduğunda uç değerler vermesi, asimetrik oluşu nedeniyle tercih edilmemiştir. Bunun yerine MAPE'nin eksiklerini gideren Simetrik Ortalama Mutlak Yüzde Hatası (sMAPE, Symmetric Mean Absolute Percent Error) çalışmaya dahil edilmiştir. Bir ölçüt açısından daha iyi olan bir model, başka bir ölçüt açısından her zaman daha iyi bir performansa sahip olmayabilir. Bu durum Sonuçlar Bölümü'nde ortaya konulmaktadır. Denklem 6.1'de verilen sMAPE, görelî hataya dayalı bir doğruluk ölçüsüdür. Sırasıyla, (6.2) ve (6.3)'de verilen RMSE ve MAE, aynı nitelikte verilere sahip eşleştirilmiş gözlemler arasında yine aynı birimde tutarsızlığın ölçüleridir.

$$sMAPE = \%100 \times \frac{\sum |\bar{d}|}{\sum (\bar{s})} \quad (6.1)$$

$$RMSE = \sqrt{\frac{1}{n} \left(\sum \bar{d}^2 \right)} = \sqrt{MSE} \quad (6.2)$$

$$MAE = \frac{1}{n} \left(\sum |\bar{d}| \right) \quad (6.3)$$

Burada $\bar{d}$, gözlem ve tahmin zaman serileri arasındaki farkı ve $\bar{s}$, gözlem ve tahmin zaman serileri toplamını temsil eder.

6.2. İyileştirme Analizi

Bu çalışmada, araştırılan modellerin en iyi performans sonuçlarının referans modelle kıyaslanmasında sMAPE, RMSE ve MAE'nin iyileştirme yüzdeleri kullanılmıştır. Tablo 8.1, her bir ölçüt için önerilen modelin yüzde gelişimini gösteren üç sütuna sahiptir. Bu sütunlarda yer alan ilgili ölçütteki iyileştirme değeri (6.4), (6.5), (6.6)'de verilen denklemler kullanılarak hesaplanmaktadır.

$$P_{sMAPE} = \%100 \times \left(\frac{sMAPE_b - sMAPE_t}{sMAPE_b} \right) \quad (6.4)$$

$$P_{RMSE} = \%100 \times \left(\frac{RMSE_b - RMSE_t}{RMSE_b} \right) \quad (6.5)$$

$$P_{MAE} = \%100 \times \left(\frac{MAE_b - MAE_t}{MAE_b} \right) \quad (6.6)$$

b ve t alt simgeleri, sırasıyla karşılaştırma modelinin ve test modelinin ilgili ölçüt sonuçlarını belirtmektedir.


7. UYGULAMA

Bu bölümde önerilen modeller ve çalışmanın nasıl uygulandığı anlatılmaktadır. Çalışmada UEZS, eğitim ve test veri seti olmak üzere iki bölüme ayrılmaktadır. Veri setinin ilk 8 yılı eğitim ve sonraki 4 yıl ise test için (%66,67-%33,33) kullanılması belirlenmiştir. Bölüm 1.3'de yer alan açık literatür çalışmaları incelendiğinde veri seti bölümlenimin %50-%50'lerden başlayabildiği görülmektedir. Veri setlerinin ayrılmasında eğitim bölümündeki örüntülerden hareketle test bölümünde yer alan örüntülerde modelin ne denli genelleştirilebildiği araştırılmaktadır. Zaman serisi boyunca benzer karakteristiğe sahip görece uzun veri setleri bakımından bölümlenimin sonuçlar üzerinde kayda değer bir etkisi olmamaktadır. Modellerin eğitiminde aşağıda detaylı bahsi geçecek olan uygulama basamakları yalnızca eğitim veri seti kullanılarak gerçekleştirilmektedir. Modellerin performanslarının değerlendirilmesi ise uygulama basamaklarının yalnızca test veri setinde koşturulmasıyla sağlanır. Böylelikle eğitim boyunca sürdürülen hatanın ağa dağıtılması işlemlerinde test veri seti ayrı tutularak modelin zaman serisinin bir kısmından ağın geri kalanını da kapsayan bir genelleştirme kabiliyeti kazanıp kazanmadığı hakkında malumat edinilmektedir.

Tahmin uygulamasının çerçevesi öncelikle UEZS'nin ayrıştırılması ve daha sonra derin öğrenme ağları kullanılarak tahmin modellerinin oluşturulmasından müteşekkil iki bölüm ihtiva etmektedir. Çerçeve kısaca şu şekilde özetlenebilir: Ham zaman serisi, EMD veya VMD yöntemleri uygulanarak n moda ayrıştırılır. Böylece, UEZS, alt-zaman serilerinin toplamı olarak ifade edilmektedir. Çalışmaya konu olan UEZS zaman serisi, varyansı stabilize etmek için ortalama değerin $\mu = 0$, standart sapmanın ise $\sigma = 1$ değerine dönüştürüldüğü yani dağılımın normale yaklaştırıldığı standardizasyon (Z-Skoru normalizasyonu) işlemine tâbi tutulmaktadır. Verilere uygulanan bu ön işlem (7.1)'de verilmektedir.


$$z_{\zeta}(t) = \frac{\zeta(t) - \mu(\zeta(\cdot))}{\sigma(\zeta(\cdot))} \quad (7.1)$$

Modal fonksiyonların Şekil 7.1'de gösterildiği üzere LSTM ve GRU'ya dayalı tahmin modellerinde eş zamanlı bir bilgi kaynağı olarak ele alınmasına olanak sağlanmaktadır yani ağ modal fonksiyonlarla desteklenmektedir.




Şekil 7.1. *LSTM&GRU tahmin modeli topolojisi*

Çalışma, UEZS ve zaman ilerledikçe sürekli ayrıştırılarak elde edilen modların kullanıldığı bir senaryo ile gerçekleştirilmiştir. Senaryoda zaman bağımsız değişkendir ve ayrıştırma t işlem zamanına kadar ki önceki verilerle gerçekleştirilmektedir. Başka bir deyişle ayrıştırma işlemi zamanda ilerlemeye bağlıdır ve gelecek veriler bu ayrıştırma işlemine dâhil edilmemektedir. Böylelikle tahmin sonuçlarına etkiyecek gelecekteki bilgi çalmak durumundan kaçınılmış olunmaktadır. Böyle bir senaryonun ihmâl edilmesi sözgelimi gerçekleştirilecek olan benzer bir tahmin çalışmasında performansı ölçütler nezdinde artıracaktır fakat fizikî tatbikî asla mümkün olmayacaktır. Ham zaman serisinin pratik karşılığa uyarlanmış olan senaryo tabanlı zaman bağımlı ayrıştırma işlemi Şekil 7.2'de verilmektedir.



Şekil 7.2. Ham zaman serisi ve ayrıştırılması

EMD yöntemi, spline ve pchip enterpolasyonu ve her ikisi için de altı adet alt seri seviyesine kadar ayrıştırma işlemi için kullanılmıştır. Öte yandan, VMD yöntemiyle ayrıştırma için bir dengeleme parametresi olarak orta bant genişliği kısıtlama parametresi belirlenmelidir. Modal fonksiyonlarda α 'nın görece küçük değerleri için yüksek frekans bileşenleri belirginleşmekte, görece yüksek değerleri içinse daha fazla filtrelenebilmektedir. Şekil 7.3'de verilen UEZS'nin güç spektral yoğunluğundaki lokal tepe noktası frekansları incelendiğinde (Hz) 0,3751, 1, 1,1253, 1,8756, 2, 2,1257, 2,8759, 3, 6,8774, 7, 9,8783, 21,8825, 22,0075, 32,2610 değerleri göze çarpmaktadır. UEZS'nin güç spektral yoğunluğu incelendiğinde 0,085'den büyük piklerin olduğu frekanslarda faydalı bilginin olduğu düşünülebilir. Bu sebeple oluşturulan veri setlerinde çeşitliliğin sağlanması amacıyla farklı bant genişliği kısıtı değerleriyle ve altı mod seviyesine kadar ayrıştırma işlemleri gerçekleştirilmektedir. Böylece destek girdiler, tahmin modeli için alt seriler olarak ham UEZS'den türetilmiştir.




Şekil 7.3. UEZS'nin güç spektral yoğunluğu

Ayrıştırma işleminden elde edilen alt zaman serilerine ek olarak, zaman bilgisinin de tahmin modelinde yer alması araştırmaya değer bulunmuştur. Ham zaman serilerine ay, ayın günü ve yılın günü bilgilerini içeren zaman serilerinin eklenmesinin etkileri incelenerek çalışma zenginleştirilmiştir. Bu zenginleştirmenin motivasyonu, ağın mevsimsel tahmin yetenekleri kazanacağı beklentisidir.

Bu çalışmada önerilen LSTM ve GRU modelleri, bazı hiper parametre ve eniyileyiciler (optimizer) değiştirilerek 1000 iterasyona kadar eğitimleri sürdürülmüştür. ADAM oldukça hızlı yakınsama, SGD (Stochastic Gradient Descent) ise ADAM'den daha iyi genelleştirme kabiliyetlerine sahip eniyileyicilerdir. Bu nedenle her iki eniyileyici de çalışmada incelenmeye değer bulunmuştur [144,145]. Eğitim sürecinde 3 farklı performans ölçütü üzerinde sürekli izleme sağlanarak en iyi sonuçlar 1000 iterasyona kadar takip edilmektedir. Çünkü iterasyon ilerledikçe eğitim performansı genellikle artar ancak bu artış sürekli olmayabilir. Böylece ölçütlerde 1000 iterasyon boyunca en iyi eğitim performansına sahip modeller belirlenmiş ve test veri setlerinde değerlendirilmiştir.

Son olarak eğitilen ağlar senaryoya uygun olarak aynı anda koşturulduklarında en çok performans gösterebildikleri ayda/aylarda ürettikleri tahminleri çıkışa yönlendiren seçici bir mekanizmaya sahip bir model ile değerlendirilmektedirler. Yani tekrarlı ağlarda yapılarının bir gereği olarak mevcut olan sıralı akış düzenleri bozulmayarak farklı mevsimsel örüntülerde tahmin performansı iyileştirilmeye çalışılmıştır. Zaman bilgisinden ağ üzerinde doğrudan yararlanılması yerine seçici bir mekanizmaya yönlendirilmiştir. Bu mekanizma üzerinden ölçütlerde aylara göre en iyi sonuçları üreten modeller seçilerek bir sınırlandırıcı üzerinden tahmin çıktıları üretilmektedir. Sınırlandırıcı bazı verimli tahmin modellerinin mümkün olmayan çıktı değerlerini düzenlemektedir. Şöyle ki, tahmincinin üreteceği negatif değerler sıfırın altına düşmemeli veya pozitif değerler yönetmeliklerle belirlenmiş güneşlenme saati tanımının üzerine çıkmamalıdır. Tasarlanan tahmin seçici mekanizma modeli (SMM) Şekil 7.4'de verilmektedir.



Şekil 7.4. SMM yapısı

SMM eş zamanlı tahmin üreteçlerini müşterek kullanabilen bir tahmin modeli seçicisi olması nedeniyle çalışma kapsamında yer almayan herhangi tahmin modelleriyle de kullanılabilir.

8. BULGULAR

Test için ayrılan zaman periyodunda, farklı optimize edici ve hiper parametrelere sahip LSTM ve GRU tabanlı modeller, UEZS kullanarak IMF ve zaman bilgisi destekli/desteksiz olarak zaman dizisindeki sıralı gelen bilgileri tahmin etmek için eğitilmektedir. Hata kriterlerindeki en iyi sonuçlar ve elde edildiği ağ modelleri Tablo 8.1'de verilmiştir. Veri seti ana sütununda modelde kullanılan veri seti hakkında bilgi verilmektedir. Bu sütundaki harfler, kullanılan veri setinin ilişkili zaman serilerini içerdiği anlamına gelir: “UEZS”, yalnız ham zaman serisinin kullanıldığını; “EMD”, EMD yöntemiyle elde edilen alt serilerin destek girdi olarak kullanıldığını; “VMD”, VMD yöntemiyle elde edilen alt serilerin destek girdi olarak kullanıldığını ve “T” harfi ise zaman bilgisinin ağa destek girdi olarak kullanıldığını ifade etmektedir. Tabloda yer alan VMD ve EMD ifadeleri alt simgelere sahiptir. Bu alt simgeler, ayrıştırma işleminin kaç alt seriye yapıldığını, diğer bir deyişle ayrıştırma işlemi sonucunda ham zaman serisinden kaç zaman serisinin elde edildiğini göstermektedir. EMD ile ilgili satırlarda “s” ve “p” harfleri sırasıyla ayrıştırma işleminde kullanılan spline veya pchip enterpolasyonunu ifade etmektedir. sMAPE, RMSE ve MAE ana sütunları, Hata, Op&Md (Optimizer & Model) ve % (Yüzde) olmak üzere üç alt sütuna ayrılmıştır. Hata alt sütunları, modelde satırdaki veri seti kullanımına karşılık ana sütunda yer alan hata ölçme türünde en iyi hata miktarını ifade etmektedir. Opt&Md alt sütunları, modelde ilgili

satırda veri seti kullanımına karşılık en iyi sonuçların elde edildiği optimize edici ve ağ modelini belirtmektedir. Alt sütunlardaki “A” harfi ADAM optimize ediciyi ve “S” harfi ise SGD optimize ediciyi temsil etmektedir. % alt sütunları, ayrıştırma yöntemleriyle desteklenmemiş yalnız ham veri setli modellerin tahmin performanslarına kıyasla ilgili ana sütun için hata ölçütünde iyileştirme yüzdesini içermektedir. Başka bir deyişle, tablonun ilk iki satırı hata iyileştirme yüzdeleri için referans olarak kullanılmaktadır. Aynı modellerin tüm ölçütlerde en iyi sonuca sahip olduğu satırlar italik olarak vurgulanmıştır. İtalik vurgulu satırlarda yer alan modellerin tüm ölçütlerde performansının en iyi olması nedeniyle daha gürbüz olduğu söylenebilir. Yine aynı kategoride yer alan benzer modellerde en iyi sonuçlar alt çizgi ile vurgulanmıştır. Hem gürbüz hem de en iyi sonuçları veren modeller kalın yazı tipiyle vurgulanmıştır.

Tablo 8.1. *En iyi model sonuçları*

Veri-seti	sMAPE			RMSE			MAE		
	Hata	Op&M	%	Hata	Op&M	%	Hata	Op&M	%
UEZST	17,958	SL		3,441	AL		2,760	AL	
UEZS	17,610	SG		3,446	SL		2,723	SG	
VMD1T	12,908	SG	28,12	2,426	AG	29,51	1,950	SG	29,33
VMD2T	13,484	AG	24,92	2,564	AG	25,48	2,040	AG	26,09
<u>VMD3T</u>	<u>12,559</u>	<u>SG</u>	<u>30,07</u>	<u>2,412</u>	<u>SG</u>	<u>29,91</u>	<u>1,869</u>	<u>SG</u>	<u>32,30</u>
VMD4T	13,629	SL	24,10	2,605	SL	24,30	2,055	SL	25,56
VMD5T	13,119	AG	26,95	2,543	AG	26,09	1,983	AG	28,14
VMD6T	14,254	AG	20,63	2,794	AG	18,82	2,180	AG	21,00
VMD1	12,048	SG	31,58	2,337	AG	32,20	1,820	SG	33,18
<u>VMD2</u>	<u>10,498</u>	<u>SG</u>	<u>40,39</u>	<u>2,148</u>	<u>SG</u>	<u>37,66</u>	<u>1,598</u>	<u>SG</u>	<u>41,31</u>
VMD3	11,964	AG	32,06	2,386	SL	30,77	1,836	SG	32,58
VMD4	11,730	SG	33,39	2,355	SG	31,66	1,782	SG	34,57
VMD5	12,367	AG	29,77	2,507	AG	27,25	1,916	AG	29,62
VMD6	12,584	AG	28,54	2,427	AG	29,57	1,891	AG	30,56
<u>EMDs1T</u>	<u>16,436</u>	<u>AL</u>	<u>8,48</u>	<u>3,024</u>	<u>AL</u>	<u>12,14</u>	<u>2,473</u>	<u>AL</u>	<u>10,38</u>
EMDs2T	18,026	AL	-0,38	3,282	AL	4,64	2,657	AL	3,72
EMDs3T	17,465	AG	2,75	3,142	AG	8,70	2,558	AG	7,30
EMDs4T	17,160	AL	4,44	3,181	AL	7,56	2,591	AL	6,10
EMDs5T	17,079	AG	4,89	3,114	AG	9,51	2,525	AG	8,51
EMDs6T	17,387	AL	3,18	3,201	AG	7,00	2,604	AG	5,64
EMDp1T	<u>16,138</u>	<u>AL</u>	<u>10,13</u>	<u>3,027</u>	<u>AL</u>	<u>12,05</u>	<u>2,465</u>	<u>SL</u>	<u>10,69</u>

Tablo 8.1. (Devam) *En iyi model sonuçları*

Veri-seti	sMAPE			RMSE			MAE		
	Hata	Op&M	%	Hata	Op&M	%	Hata	Op&M	%
EMDp2T	17,681	AL	1,54	3,301	AL	4,09	2,681	AL	2,85
EMDp3T	16,777	AL	6,58	3,147	AL	8,55	2,547	AL	7,71
EMDp4T	17,136	AL	4,58	3,136	AL	8,86	2,557	AL	7,33
EMDp5T	17,225	AL	4,08	3,192	AL	7,25	2,577	AL	6,62
EMDp6T	17,572	AL	2,15	3,204	AG	6,89	2,617	AG	5,17
EMDs1	<u>15,594</u>	<u>AL</u>	<u>11,45</u>	<u>2,925</u>	<u>AL</u>	<u>15,13</u>	<u>2,344</u>	<u>SG</u>	<u>13,93</u>
EMDs2	17,601	SG	0,05	3,238	SG	6,03	2,590	SG	4,90
EMDs3	16,599	AL	5,74	3,090	AL	10,34	2,483	AL	8,81
EMDs4	17,085	AL	2,98	3,169	AG	8,05	2,554	AG	6,20
EMDs5	16,626	AG	5,58	3,070	AG	10,93	2,477	AG	9,02
EMDs6	15,907	AL	9,67	3,005	AL	12,80	2,398	AL	11,93
<u>EMDp1</u>	<u>15,455</u>	<u>AL</u>	<u>12,24</u>	<u>2,908</u>	<u>AL</u>	<u>15,61</u>	<u>2,334</u>	<u>AL</u>	<u>14,30</u>
EMDp2	17,556	AL	0,31	3,327	AL	3,45	2,674	AL	1,80
EMDp3	17,092	AL	2,94	3,159	AL	8,33	2,565	AL	5,79
EMDp4	17,276	AL	1,90	3,135	AG	9,04	2,562	AG	5,90
EMDp5	16,870	AL	4,20	3,135	AG	9,03	2,540	AG	6,73
EMDp6	17,115	AL	2,81	3,146	AL	8,72	2,553	AL	6,24

Tablo 8.1'den, UEZS ile ağa destek zaman bilgisinin sunulmasının, ayırıştırma yöntemlerinin kullanılmadığı ağlarda tahmin performansı üzerinde olumlu bir etkisinin bulunmadığı görülmektedir. EMD veya VMD yöntemleri hem zaman bilgisi ile ağ desteklendiği hem de kullanılmadığı her iki durumda da tahmin başarısını iyileştirmektedir. Eklenen zaman bilgisinin ağ performansını istisnalar olsa da genel olarak olumsuz etkilediği sonucuna ulaşılmıştır. Bu istisnaî iyileştirmeler, ağın zaman bilgisiyle desteklenmemesindeki performans katkısına kıyasla oldukça yetersizdir.

Farklı filtreleme yaklaşımları, zaman serilerinden farklı anlamlı bilgileri veya anlamlı bilgileri farklı çözünürlüklerde ortaya çıkarabilirler. EMD ve VMD yöntemleri, geçmişe ait bilgileri bir nevi filtreleme görevi görmektedirler. Ağın tahmin performansındaki önemli artış nedeniyle, hatanın ağ girişi ile çıkışı arasında hücre modellerine iyi dağıtılabildiği ve zaman serisinin tahmin anı öncesine ait filtrelenmiş geçmiş bölümünün tahmin edilecek verilerle zaman alanında korelasyonlar içerdiği söylenebilir.

Tablo 8.1'den de görülebileceği üzere, LSTM ağıları, EMD yöntemi açısından aynı maksimum iterasyona kadar eğitilen tüm ağlar arasında çoğunlukla en iyi sonuçları vermektedir. Bu eğitim, SGD yöntemine kıyasla hataları ağ ağırlıklarına hızlı bir şekilde dağıtma yeteneğine sahip ADAM optimizasyonunda genellikle daha başarılı sonuçlar üretmektedir.

Farklı enterpolasyon tekniklerinin kullanılmasıyla, tahmin performansı farklı hata ölçütlerinde bazen pchip bazen de spline açısından gelişim göstermektedir. Bu performans artışı $\pm\%16$ 'i geçmese de genellikle pchip tekniğinin kullanılmasıyla olmaktadır.

Ayrıştırma tekniklerinde bilgiler süzülerek alt zaman serileri elde edilir. İşlem sonucunda tüm alt zaman serilerinin ve artıkların (residual) toplamı ham zaman serisini vermektedir. EMD yöntemi ampirik bir yaklaşım olduğundan ayrıştırma işlemi yeni alt zaman serileri eklenerek genişletilmek istenirse önceki alt zaman serilerini de içerecektir. Başka bir deyişle, nispeten çok sayıda alt zaman serisine ayrıştırma, nispeten az sayıda alt zaman serisine ayrıştırmayı içermektedir. Öte yandan, VMD'nin çözüme varyasyonel bir problem olarak yaklaşması nedeniyle, bu çalışmada olduğu gibi (trendleri asıl sinyal kabul ederek) görece yüksek SNR'lı (Sinyal-gürültü oranı) zaman serilerinde farklı seviyelerde ayrıştırma işleminde alt zaman serileri oldukça farklılık göstermektedir.

Temel düzeyde, az sayıda alt zaman serisine ayrıştırma hem EMD hem de VMD için en iyi tahmin performansına sahip modellerle sonuçlanmaktadır. Ağı desteklemek için ağ girdi boyutunu artırmak her zaman performansı artırmamaktadır. Bu durum, EMD yönteminin özyinelemeli ampirik doğası gereği tahmine yeterince katkı sağlamayan girdilerin zaman zaman beklenen çıktı ile korelasyonun bulunması ve hatanın ağa zaman zaman dağıtılmasıyla değer kazanan ağırlıkların toplamda tahmin başarısında zayıflamaya sebebiyet vermesiyle açıklanabilir. Eğer hiç giriş-çıkış ilişkisi bulunmasaydı ilgili ağırlıkların sıfıra gitmesi ve sonuç üzerinde etkilerinin ortadan kalkması beklenirdi. Zaman bilgisinin ağı desteklemek için kullanılmasının olumsuz etkisi bu çıkarımı doğrulamaktadır.


VMD yönteminin kullanılması, farklı ölçütlerde tahmin performansına $\%18$ ila $\%42$ arasında bir katkı sağlamaktadır. Bu katkı EMD yöntemi açısından maksimum $\%15$ düzeyindedir. Tüm modeller arasında en iyi sonuç, SGD ile eniyilenmiş GRU ağında

VMD yöntemi kullanılarak ancak zaman bilgisi kullanılmadan elde edilmektedir. VMD ile farklı α değerlerinde fakat iki alt seri düzeyinde ayrıştırma, ağı desteklemek için en iyi alt serileri üretmekte ve tüm modeller arasında en iyi tahmin performansını yakalamaktadır. sMAPE, RMSE ve MAE için en iyi performans sonuçları sırasıyla 10,498, 2,148 (Sa) ve 1,598 (Sa) olarak elde edilmiştir. Ayrıca, her ölçütte tahmin performansını eniyileyeabildiği için modelin en gürbüz olarak değerlendirilmesi mümkündür. Önerilen bu model, tüm kriterlerde referans modele kıyasla tahmin performansında en iyi gelişmeyi elde etmektedir. Ölçütlerde iyileştirme sMAPE'de %40,39, RMSE'de %37,66 ve MAE'de %41,31 şeklindedir.

VMD yaklaşımını kullanan GRU ağı ve EMD yaklaşımını kullanan LSTM ağı genel olarak kendi kategorilerinde daha iyi tahmin performansı elde etmektedirler. En iyi performansa sahip model, LSTM ağlarına nazaran daha basit yapıya sahip GRU ağlarında ve ADAM'a göre daha iyi genelleme kabiliyetine sahip SGD eniyileyici ile elde edilmektedir. Bu durum, iki alt seri düzeyinde VMD ile filtrelenerek elde edilen bilgilerin basit bir yapıya aktarılmasıyla genellenenin daha iyi sağlandığı şeklinde yorumlanabilir.

8.1. SMM Mevsimsel Analizi


Dünyanın eksen eğikliği ve Güneş etrafındaki hareketi değişen meteorolojik koşulları tetiklemekte ve mevsimsel farklılıklara neden olmaktadır. UEZS'deki farklı mevsimsel örüntüler için tahmin performansları, Şekil 8.1'deki Kiviat diyagramlarında hata ölçütlerinde oransal mukayeseyi mümkün kılacak min-max normalizasyonlu olarak gösterilmektedir. Diyagram, önerilen SMM modelindeki hataların referans modelle karşılaştırıldığında herhangi bir ay için azalarak merkeze yaklaştığını göstermektedir. Diyagramlara göre, önerilen model, tüm ölçütlerde her ay için ham tahmin modelinin sonuçlarını geliştirmeyi başarmıştır.



Şekil 8.1. (a) sMAPE, (b) RMSE ve (c) MAE ölçütlerinde normalize sonuçlar

Şekil 8.1(a)'da görüldüğü üzere referans modelin sMAPE ölçütü açısından sonbahar, yaz ve Mart, Nisan aylarında daha doğru tahminlerde bulunduğu, kış aylarında ise diğer mevsimlere nispetle tahmin kabiliyetinin düştüğü gözlemlenmektedir. Önerilen modelin özellikle kış aylarında tahmin performansını çok daha iyi geliştirdiği görülmektedir. Şekil 8.1 (b) ve Şekil 8.1 (c) incelendiğinde RMSE ve MAE açısından tahmin performansı tam olarak aynı olmamakla birlikte benzerlik göstermektedir. Fark, çoğunlukla Mart ayında belirginleşmiştir. Bu durumun temel sebebi (6.2) ve (6.3) denklemlerinden anlaşılmaktadır. Mart ayında modellerin ürettiği ters işaretli hataların belirginleşmesi ve (6.2) ölçümünde bu durumun sonuçlara işaretten bağımsız yansımalarıdır. Önerilen modelin referans modele göre bütün mevsimlerde performansının önemli ölçüde arttığı gözlemlenmektedir.

Şekil 8.2, hata ölçütlerinde aylara göre önerilen modelin tahmin performansındaki iyileşmeleri göstermektedir. Buna göre önerilen model sMAPE ölçütünde minimum %32,69, maksimum %58,2; RMSE ölçütünde en az %33,37, en fazla %52,21 ve MAE ölçütünde en az %35,9, en fazla %54,57 iyileştirme sağlayabilmektedir. SMM çoğunlukla VMD2 model tahminlerinden yararlanmakla birlikte sMAPE ölçütünde Şubat, RMSE ölçütünde Mart, Haziran, Ağustos ve MAE ölçütünde ise Aralık ayında başka modellerin tahminlerinden istifade etmektedir.




Şekil 8.2. SMM aylara göre iyileştirme yüzdeleri

Şekil 8.2'de görece daha az gelişme yakalanan aylarda, referans modelin diğer aylara kıyasla nispeten başarısının düşük olduğu görülmektedir. Özellikle referans model performansının görece düşük olduğu aylarda, önerilen modelin ayrıştırma yöntemi sayesinde zaman serisini filtreleyerek daha iyi kullanabilmekte ve tahmin performansını iyileştirmekte olduğu görülmektedir. Bu aylarda faydalı bilgilerin örtülü kaldığı ve ayrıştırma işlemiyle ortaya çıkarıldığı düşünülebilir. Başka bir deyişle, referans modelin tahmin ilişkisi kurmakta zorlandığı zaman periyotlarında, zaman serilerindeki gizli kalan faydalı bilgiler ayrıştırma yöntemi ile ağa tanıtılmaktadır. Önerilen model Ağustos tahminlerinde en fazla iyileşmeyi elde etmektedir. Şubat ayında da yine iyileşme olmasına rağmen iyileştirme en düşük oranda kalmaktadır. Ölçütlerde iyileştirmenin Ocak ayında birbirine yakın olduğu görülmektedir. Şubat ve Mart aylarında RMSE açısından iyileştirmede önemli bir değişiklik bulunmazken sMAPE ve MAE açısından yaklaşık iki kat artış görülmektedir. Nisan ve Mayıs aylarında sMAPE ve MAE ölçütlerinde iyileştirme artış göstermiş fakat RMSE açısından düşmüştür. Yaz aylarıyla birlikte aylara göre her ölçütte sürekli benzer bir iyileştirmede artış görülmektedir. Mevsim geçişinin olduğu Eylül ayıyla birlikte her ölçütte iyileştirmede düşüş olduğu görülmektedir ve en fazla düşüş sMAPE ölçütünde gerçekleşmektedir. Sonbahar boyunca sMAPE ve MAE açısından iyileştirmede düşüş süreklidir fakat RMSE açısından

Ekim ayı itibariyle iyileştirmede artış başlamaktadır. Bütün ölçütlerde Kasım ayıyla beraber başlayan iyileştirme artışı Ocak ayıyla beraber düşüşe geçmektedir. Ölçütlerde SMM tahmin sonuçları EK-2’de yer almaktadır.

9. İSTATİSTİKİ BULGULAR

Bu bölümde çalışmada kullanılan METAR verilerine istatistiksel bir yaklaşımla yer verilmektedir. Mevsimsel farklılıkların ortaya konulabilmesi için veriler ay bazında bir çözünürlük çerçevesinde on iki senelik süre zarfı içerisinde incelenmektedir. Şekil 9.1(a)’de LTBY’nin ay bazında düzenlemelerle belirlenmiş güneşlenme süresi ve bu sürenin eğitim uçuşları için ne kadarının kullanılabildiği on iki senelik süre zarfında toplamlar üzerinden bir oranla ifade edilmektedir. Buna göre incelenen süre zarfında güneşlenme süresinin meteorolojik hâdiseler nedeniyle hiçbir zaman tamamının kullanılamadığı açıkça görülmektedir. Diyagrama göre güneşlenme süresi en az Ekim ve Mart aylarında şartlar açısından kısıtlanmaktadır. Güneşlenme süresinin oldukça fazla olduğu yaz aylarında eğitim uçuşları için tercih edilmeyen şartların en yüksek oranda sıcaklık kaynaklı gerçekleştiği görülmektedir. Bu şartların başında yer alan sıcaklık faktörü Şekil (9.1)(b)’de yer almakla birlikte sıcaklığın eğitim uçuşlarını etkileyerek güneşlenme süresi kullanımını kısıtlama süresi toplam miktarını ifade etmektedir.




(a) Uçuşa elverişli saat miktarı (b) Sıcaklık faktörü

Şekil 9.1. Güneşlenme süresinin (a) uçuşa elverişli ve (b) sıcaklık etkisinde kalma miktarları

Sıcaklıkla ilgili kısıt aşırı soğuk ve aşırı sıcakları kapsamakta olduğundan kış aylarında ve yaz aylarında sürekli etkindir. Şekil 9.1’den anlaşıldığı üzere sıcaklık kısıtı aşırı sıcaklar açısından yaz aylarında uçuşa elverişliliği daha çok etkilemektedir.

Şekil 9.2’de on iki senelik süre zarfında meteorolojik hâdiselerin eğitim uçuşları üzerindeki toplam etkileri ortaya konulmaktadır. Diyagramlar incelenirken birden fazla hâdisenin aynı anda güneşlenme süresinin kullanımını kısıtlayabileceği göz önünde bulundurulmalıdır.



Şekil 9.2. Meteorolojik hadislerin güneşlenme süresini kısıtlama toplam miktarları

Şekil 9.2’de sene boyunca yüksek kapalılık oranı veya düşük taban yüksekliği nedeniyle bulutların eğitim uçuşlarını olumsuz etkilediği görülmektedir. Özellikle Ocak ve Aralık ayları olmak üzere rüyetin düşmekte ve VFR uçuşları olumsuz etkilemektedir. Mayıs ve Haziran aylarında görülen bulutların daha ziyade dikey gelişmeli olduğu bu aylarda raporlanan oraj varlığından anlaşılmaktadır. Yine bu aylarda raporlanan sağanak yağışların oraja sebep olan bulutlar nedeniyle oluştuğu düşünülebilir. İlkbahar ve yaz aylarında sis faktörünün oldukça azaldığı veya ortadan kalktığı söylenebilir. Kış ve ilkbahar aylarında yağışlar uçuşları oldukça etkilemektedir. Mevsim geçişinde bulunan Haziran ayında da yağışların etkisi diğer yaz aylarından ve sonbahardan fazla olduğu görülmektedir. Rüyetin en çok Ocak ve Aralık aylarında düştüğü görülmektedir.

Uçuş eğitim organizasyonları planlamalarını meteorolojik hâdiselerle birlikte ihtiyaçlarına göre birtakım etmenleri de göz önüne alarak düzenlemektedirler. Planlama sürecine öğretmen ile aday pilot ve uçak durumları da dâhil edilmektedir. ESTÜ-P’de planlama sürecinde en az 2 saat sorti süresi ve uçuş operasyonundan sonra emniyet maksatlı olarak en az 1 saat boyunca uygun hava koşullarının korunuyor olması durumu dikkate alınmaktadır. Bu sebeple 3 ve üzeri uçuşa elverişli saat içeren günler EK-4’de

tablolaştırılmıştır. İçerdikleri uçuşa elverişli saat miktarlarına göre gün sayıları yıllara ve aylara göre EK-4’de yer almaktadır.

10. TARTIŞMA VE ÖNERİLER

UEZS meteorolojik gözlemlerden elde edilmiştir. Dolayısıyla, uçuşa elverişliliğin kaotik doğası araştırmaları son derece zorlaştırmaktadır. Bu sorunla mümkün olduğunca başa çıkılabilmesi için çalışmada LSTM ve GRU modelleriyle beraber EMD ve VMD ayrıştırma yöntemlerinin birlikte kullanımına dayanan melez tahmin modelleri önerilmektedir. Böylece ayrıştırma yöntemleri ile veri alternatifleri oluşturularak ağın desteklenmesi amaçlanmaktadır. Ek olarak ağın mevsimsel tahmin yetenekleri kazanabileceği düşüncesinden hareketle tahminin gerçekleştirildiği zamana ilişkin bilgilerin ağa sağlandığı veri kombinasyonlarını araştırılmıştır. Çalışma, pratik karşılıkların elde edilebildiği bir senaryo üzerinde kurgulanmıştır. Böylece geleceğe yönelik verilerin tahmin sürecine dâhil edilmediği yinelemeli bir ayrıştırma yaklaşımı uygulanmaktadır. EMD farklı enterpolasyon yaklaşımlarına dayalı olarak ve VMD ise farklı kısıtlama parametreleriyle uygulanmıştır. Her iki ayrıştırma yöntemi de farklı mod sayılarında genişletilerek veri setleri hazırlanmıştır. Ayrıştırma yöntemleri zaman alanı boyunca tahmin modellerini bilginin farklı çözünürlükleriyle desteklemek için kullanılmaktadır. Çalışmada model seçici bir mekanizma tanıtılarak eğitilen modellerin tamamının performansından istifade edilmektedir.

- Tahmin vaktine ilişkin ay, ayın günü ve yılın günü bilgileri ağlara çoğunlukla katkı sağlamamaktadır.
- Her iki ayrıştırma yöntemi de zaman bilgisi kullanılan ve kullanılmayan ağlara destek sağlayabilmektedir.
- Gereksiz girdilerin genel olarak ağın öğrenme yeteneği üzerinde olumsuz bir etkisi olmaktadır. Anlamlı bilgiler içeren girdilerle girişimde bulunan gereksiz girdiler, hatanın ağ ağırlıklarına dağılımını olumsuz etkilemektedir. Faydalı girdiye ilişkin ağ ağırlığı değerini kaybederken faydasız ağ ağırlığı değer kazanabilmektedir. Girdi sayısı optimal düzeyde tutulmalıdır.
- EMD ve VMD ayrıştırma yöntemleri, tahminde kullanılan geçmiş bilgiler için filtre görevi görmektedir. Böylece anlamlı bilgiyi gürültüden süzerek

ağları destekleyebilmektedir. Filtrelenmiş geçmiş bilgiler, tahmin başarısını önemli ölçüde artırmaktadır.

- Genel olarak, VMD yöntemi ile GRU ağlarının kullanımı ve EMD yöntemi ile LSTM ağlarının kullanımı daha başarılı tahminler üretmektedir.
- VMD yöntemiyle SGD eniyileyici ve EMD yöntemiyle ADAM eniyileyici kullanıldığında genel olarak daha başarılı modeller kurulabilmektedir.
- Önerilen modelin performansı farklı mevsimsel örüntüler açısından değerlendirildiğinde, herhangi bir hata ölçütü nezdinde tahmin performansını en az %32,69 iyileştirmeyi başarmıştır.
- SMM'in tahmin modellerini eş zamanlı kullanılması yani farklı mevsimsel örüntülerde farklı tahmin modellerinden yararlanmaya imkân sağlaması tahmin performansı artırmaktadır.
- Önerilen modelin planlama sürecinde öngörülerini arttırabilecek sonuçlar ürettiği ve böylece planlama süreçlerine katkı sağlayacağı sonucuna ulaşılmıştır.

DA-RNN derin öğrenme modeli SMM'de tanıtılan model seçici mekanizmasına benzerdir fakat veri seçici bir dikkat (attention) mekanizmasına sahip olması nedeniyle araştırmaya uygun görülmektedir. DA-RNN modelinin sahip olduğu dikkat (attention) mekanizması ağ seçici giriş kabiliyetleri kazandırmakta olduğundan tahmin sonuçlarına etkisi araştırılarak SMM ile karşılaştırılabilir. Alt zaman serileriyle birlikte dikkat mekanizmasının tahmin performansı araştırılmaya değerdir. Yine zaman bilgisi açısından SMM'in veri seçme kabiliyeti farklı çözünürlüklerde değerlendirilebilir. Parçacık sürü, genetik, arı v.b. optimizasyon algoritmalarıyla veya grid search, brute force gibi ilkel algoritmalarla gerek ayrıştırma gerek derin öğrenme hiper parametreleri üzerinde deneysel kabullerden hareketle bir ayrıştırma eniyileme çalışması yapılabilir. Çalışma girdi veri setleri nezdinde ele alınarak temel bileşenler analizine yönlendirilebilir. Uçuşa elverişliliğin doğrusal ve doğrusal olmayan özelliklerinden yararlanabilecek SARIMA, karar ağaçları v.s. melez modelleri üzerinde çalışma tekrar edilebilir veya tanıtılan SMM'ye entegre edilebilir. Sinir ağı modellerinde kullanılan verilerin tâbi tutulduğu ön işlemler ayrıca değerli araştırma konuları arasındadır. Bu ve benzeri çalışmalarda model hiper parametreleri aynı tutularak farklı normalizasyon işlemleri üzerinde çalışmalar genişletilebilir.

KAYNAKÇA

- [1] Anadolu Üniversitesi. (2016). *Meteoroloji-II (1. Baskı)*. Eskişehir.
- [2] Tatli, A., ve Kahvecioğlu, S. (2016). NARX neural networks based time series prediction for amount of airworthiness time. *2016 National Conference on Electrical, Electronics and Biomedical Engineering (ELECO)*, 130–134.
- [3] Kumar, D. N., ve T. Sathish. (2004). Forecasting hydrologic time series using artificial neural networks. *Proceedings of International Conference on Theoretical, Applied, Computational and Experiential Mechanics*.
- [4] Bağan, H., ve Gerede, E. (2019). Use of a nominal group technique in the exploration of safety hazards arising from the outsourcing of aircraft maintenance. *Safety Science*, 118, 795–804. <https://doi.org/10.1016/j.ssci.2019.06.012>
- [5] Ekici, S. (2020). Investigating routes performance of flight profile generated based on the off-design point: Elaboration of commercial aircraft-engine pairing. *Energy*, 193, 116804. <https://doi.org/10.1016/j.energy.2019.116804>
- [6] Sahay, A. (2012). *An overview of aircraft maintenance*. Elsevier.
- [7] Boyd, D., ve Stolzer, A. (2015). Causes and Trends in Maintenance-Related Accidents in FAA-Certified Single Engine Piston Aircraft. *Journal of Aviation Technology and Engineering*, 5(1).
- [8] Usanmaz, O. (2011). Training of the maintenance personnel to prevent failures in aircraft systems. *Engineering Failure Analysis*, 18(7), 1683–1688. <https://doi.org/https://doi.org/10.1016/j.engfailanal.2011.02.010>.
- [9] Endsley, M. R., ve Robertson, M. M. (1996). Team Situation Awareness in Aviation Maintenance. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 40, 1077–1081.
- [10] Graeber, R. C., ve Marx, D. A. (1993). Reducing human error in aviation maintenance operations. *Flight Safety Foundation 46th Annual International Air Safety Seminar*, Kuala Lumpur, Malaysia.

- [11] Kritzinger, D. (2017). Assessments for Initial Airworthiness Certification. In D. Kritzinger (Ed.), *Aircraft System Safety* (pp. 1–21). Woodhead Publishing. <https://doi.org/https://doi.org/10.1016/B978-0-08-100889-8.00001-5>
- [12] Marais, K. B., ve Robichaud, M. R. (2012). Analysis of trends in aviation maintenance risk: An empirical approach. *Reliability Engineering and System Safety*, 106, 104–118. <https://doi.org/10.1016/j.ress.2012.06.003>
- [13] Max, D. A., ve Graeber, R. C. (1994). Human error in maintenance. *Aviation Psychology in Practice*, 1, 87–104.
- [14] Weigmann, D. A., ve Shappell, S. A. (1997). Human factors analysis of postaccident data: Applying theoretical taxonomies of human error. *The International Journal of Aviation Psychology*, 7(1), 67–81.
- [15] Shappell, S., Detwiler, C., Holcomb, K., Hackworth, C., Boquet, A., Wiegmann, D. A. (2007). Human Error and Commercial Aviation Accidents: An Analysis Using the Human Factors Analysis and Classification System. *Human Factors*, 49(2), 227–242. <https://doi.org/10.1518/001872007X312469>
- [16] Campbell, R., ve Bagshaw, M. (2002). Human Error and Reliability. In *Human Performance and Limitations in Aviation* (pp. 116–124). John Wiley & Sons, Ltd. <https://doi.org/https://doi.org/10.1002/9780470774472.ch6>
- [17] Yazgan, E. (2018). Development taxonomy of human risk factors for corporate sustainability in aviation sector. *Aircraft Engineering and Aerospace Technology*, 90, 1012–1022. <https://doi.org/10.1108/AEAT-04-2018-0133>
- [18] Üçkardeş, İ. (2012). *Risk analizi ve havacılık sektöründe kaza risklerinin değerlendirilmesi*. Adana: Çukurova Üniversitesi, Fen Bilimleri Enstitüsü.
- [19] Pearson, C. (2002). VFR flight not recommended: a study of weather-related fatal aviation accidents.
- [20] Caro, P. W. (1973). Aircraft simulators and pilot training. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 15(6), 502–509.
- [21] Griffin, G. R., ve McBride, D. K. (1986). Multitask performance: predicting success in naval aviation primary flight training (no. NAMRL-1316).

- [22] Foyle, D. C., Kaiser, M. K., ve Johnson, W. W. (1992). Visual cues in low-level flight: implications for pilotage, training, simulation, and enhanced/synthetic vision systems. *American Helicopter Society 48th Annual Forum*, 253–260.
- [23] Kern, T. T. (1997). *Redefining Airmanship*. McGraw Hill Professional.
- [24] Menendez, R. G., ve Bernard, J. E. (2000). Flight simulation in synthetic environments. *19th DASC. 19th Digital Avionics Systems Conference*. Proceedings (Cat. No. 00CH37126), Vol. 1. IEEE, 2A5-1.
- [25] Fitzgibbons Amy, Davis Donald, ve Schutte Paul C. (2004). Pilot personality profile using the NEO-PI-R.
- [26] Yazgan, E., Cilingir, F. C., Erol, D., Anagün, A. S. (2017). An analysis of the factors influencing score achieved during pilot training. *Transactions of the Japan Society for Aeronautical and Space Sciences*, 60(4), 202–211.
- [27] ESTÜ. (2021). *Pilotaj Bölümü Eğitim El Kitabı*. Eskişehir Teknik Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi.
- [28] SHGM. (2020). Sivil Havacılık Genel Müdürlüğü Faaliyet Raporu. <http://web.shgm.gov.tr/documents/sivilhavacilik/files/pdf/kurumsal/faaliyet/2020.pdf> (Erişim tarihi: 28.11.2021)
- [29] Atasoy, V. E., ve Ekici, S. (2020). Exploring experiential indicators in flight training organization: a case study. *Aircraft Engineering and Aerospace Technology*, 92(4), 541–549. <https://doi.org/10.1108/AEAT-08-2019-0166>
- [30] Atasoy, V. E. (2015). *Bir uçuş eğitim organizasyonunun üretkenliğine etki eden faktörlerin incelenmesi*. Eskişehir: Anadolu Üniversitesi, Fen Bilimleri Enstitüsü.
- [31] Tatli, A., Kahvecioglu, S., ve Karakoc, H. (2020). Time-Series Prediction for Amount of Airworthiness Based on Time-Delay Neural Networks. *Elektronika Ir Elektrotehnika*, 26(5), 28–32. <https://doi.org/10.5755/j01.eie.26.5.25843>
- [32] Tatli, A., Bocu, E., Filik, T., ve Karakoc, T. H. (2022). A case study on the effect of meteorological events on the efficiency of flight training organization. *Aircraft Engineering and Aerospace Technology*, 94(7), 1109–1116. <https://doi.org/10.1108/AEAT-10-2021-0295>

- [33] ESTÜ. (2020). *Uçuş Kayıt Defteri*. Eskişehir Teknik Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi.
- [34] Garg, A., ve Deshmukh, S. G. (2006). Maintenance management: literature review and directions. *Journal of Quality in Maintenance Engineering*, 12(3), 205–238. <https://doi.org/10.1108/13552510610685075>
- [35] Hu, H., Zhang, J., ve Li, T. (2020). A Comparative Study of VMD-Based Hybrid Forecasting Model for Nonstationary Daily Streamflow Time Series. *Complexity*, 2020, 1–21. <https://doi.org/10.1155/2020/4064851>
- [36] Sun, Z., Zhao, S., ve Zhang, J. (2019). Short-Term Wind Power Forecasting on Multiple Scales Using VMD Decomposition, K-Means Clustering and LSTM Principal Computing. *IEEE Access*, 7, 166917–166929. <https://doi.org/10.1109/ACCESS.2019.2942040>
- [37] Kim, S., Lee, G., Kwon, G.-Y., Kim, D.-I., Shin, Y.-J. (2018). Deep Learning Based on Multi-Decomposition for Short-Term Load Forecasting. *Energies*, 11(12), 3433. <https://doi.org/10.3390/en1123433>
- [38] Tatlı, A. (2016). *Uçuşa elverişliliğin meteorolojik açıdan incelenmesi ve kısa vadeli kestirim modeli için zaman serilerinde yapay sinir ağları yaklaşımı: Hasan Polatkan Havaalanı örneği*. Eskişehir: Anadolu Üniversitesi, Fen Bilimleri Enstitüsü.
- [39] Bedi, J., ve Toshniwal, D. (2018). Empirical Mode Decomposition Based Deep Learning for Electricity Demand Forecasting. *IEEE Access*, 6, 49144-49156. <https://doi.org/10.1109/ACCESS.2018.2867681>
- [40] Han, L., Zhang, R., Wang, X., Bao, A., Jing, H. (2019). Multi-step wind power forecast based on VMD-LSTM. *IET Renewable Power Generation*, 13(10), 1690-1700. <https://doi.org/10.1049/iet-rpg.2018.5781>
- [41] Bandara, K., Bergmeir, C., ve Smyl, S. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*, 140, 112896. <https://doi.org/10.1016/j.eswa.2019.112896>

- [42] Chen, D., Zhang, J., ve Jiang, S. (2020). Forecasting the Short-Term Metro Ridership With Seasonal and Trend Decomposition Using Loess and LSTM Neural Networks. *IEEE Access*, 8, 91181-91187. <https://doi.org/10.1109/ACCESS.2020.2995044>
- [43] Chacon, H. D., Kesici, E., ve Najafirad, P. (2020). Improving Financial Time Series Prediction Accuracy Using Ensemble Empirical Mode Decomposition and Recurrent Neural Networks. *IEEE Access*, 8, 117133-117145. <https://doi.org/10.1109/ACCESS.2020.2996981>
- [44] Liu, D., Jiang, W., Mu, L., Wang, S. (2020). Streamflow Prediction Using Deep Learning Neural Network: Case Study of Yangtze River. *IEEE Access*, 8, 90069-90086. <https://doi.org/10.1109/ACCESS.2020.2993874>
- [45] Zhou, S., Zhou, L., Mao, M., Tai, H.-M., Wan, Y. (2019). An Optimized Heterogeneous Structure LSTM Network for Electricity Price Forecasting. *IEEE Access*, 7, 108161-108173. <https://doi.org/10.1109/ACCESS.2019.2932999>
- [46] Zhang, Y., Zhao, Y., ve Gao, S. (2019). A Novel Hybrid Model for Wind Speed Prediction Based on VMD and Neural Network Considering Atmospheric Uncertainties. *IEEE Access*, 7, 60322-60332. <https://doi.org/10.1109/ACCESS.2019.2915582>
- [47] Huang, G., Li, X., Zhang, B., Ren, J. (2021). PM2.5 concentration forecasting at surface monitoring sites using GRU neural network based on empirical mode decomposition. *Science of The Total Environment*, 768, 144516. <https://doi.org/10.1016/j.scitotenv.2020.144516>
- [48] Huang, H., Chen, J., Huo, X., Qiao, Y., Ma, L. (2021). Effect of Multi-Scale Decomposition on Performance of Neural Networks in Short-Term Traffic Flow Prediction. *IEEE Access*, 9, 50994-51004. <https://doi.org/10.1109/ACCESS.2021.3068652>
- [49] E, J., Ye, J., He, L., Jin, H. (2019). Energy price prediction based on independent component analysis and gated recurrent unit neural network. *Energy*, 189, 116278. <https://doi.org/10.1016/j.energy.2019.116278>

- [50] Başaran Filik, Ü., ve Filik, T. (2017). Kısa-Dönem Rüzgâr Hızının Tahmininde Otoresgresif ve Yapay SinirAğları Tabanlı Yeni Bir Hibrit Yaklaşım. *Karaelmas Fen ve Mühendislik Dergisi*, 7, 419-427.
- [51] Filik, Ü. B., ve Filik, T. (2017). Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir. *Energy Procedia*, 107, 264-269. <https://doi.org/10.1016/j.egypro.2016.12.147>
- [52] Filik, T., ve Filik, Ü. B. (2017). Very Short Term Wind Speed Forecasting Using Multivariable Dense Data with WLS-MARMA Model. *Energy Procedia*, 107, 259-263. <https://doi.org/10.1016/j.egypro.2016.12.145>
- [53] Qiao, W., ve Yang, Z. (2020). Forecast the electricity price of U.S. using a wavelet transform-based hybrid model. *Energy*, 193, 116704. <https://doi.org/10.1016/j.energy.2019.116704>
- [54] Wang, B., Kong, W., Guan, H., Xiong, N. N. (2019). Air Quality Forecasting Based on Gated Recurrent Long Short Term Memory Model in Internet of Things. *IEEE Access*, 7, 69524-69534. <https://doi.org/10.1109/ACCESS.2019.2917277>
- [55] Yang, G., Wang, Y., ve Li, X. (2020). Prediction of the NO emissions from thermal power plant using long-short term memory neural network. *Energy*, 192, 116597. <https://doi.org/10.1016/j.energy.2019.116597>
- [56] Wang, Y., Shen, Y., Mao, S., Chen, X., Zou, H. (2019). LASSO and LSTM Integrated Temporal Model for Short-Term Solar Intensity Forecasting. *IEEE Internet of Things Journal*, 6(2), 2933-2944. <https://doi.org/10.1109/JIOT.2018.2877510>
- [57] Lee, W., Kim, K., Park, J., Kim, J., Kim, Y. (2018). Forecasting Solar Power Using Long-Short Term Memory and Convolutional Neural Networks. *IEEE Access*, 6, 73068-73080. <https://doi.org/10.1109/ACCESS.2018.2883330>
- [58] Pang, Y., Yao, H., Hu, J., Liu, Y. (2019, Haziran 17). A Recurrent Neural Network Approach for Aircraft Trajectory Prediction with Weather Features From Sherlock. *AIAA Aviation 2019 Forum*. <https://doi.org/10.2514/6.2019-3413>

- [59] Zhou, H., Zhang, Y., Yang, L., Liu, Q., Yan, K., Du, Y. (2019). Short-Term Photovoltaic Power Forecasting Based on Long Short Term Memory Neural Network and Attention Mechanism. *IEEE Access*, 7, 78063-78074. <https://doi.org/10.1109/ACCESS.2019.2923006>
- [60] Yu, Y., Cao, J., ve Zhu, J. (2019). An LSTM Short-Term Solar Irradiance Forecasting Under Complicated Weather Conditions. *IEEE Access*, 7, 145651-145666. <https://doi.org/10.1109/ACCESS.2019.2946057>
- [61] Yang, T., Li, B., ve Xun, Q. (2019). LSTM-Attention-Embedding Model-Based Day-Ahead Prediction of Photovoltaic Power Output Using Bayesian Optimization. *IEEE Access*, 7, 171471-171484. <https://doi.org/10.1109/ACCESS.2019.2954290>
- [62] Fan, Y., Xu, K., Wu, H., Zheng, Y., Tao, B. (2020). Spatiotemporal Modeling for Nonlinear Distributed Thermal Processes Based on KL Decomposition, MLP and LSTM Network. *IEEE Access*, 8, 25111-25121. <https://doi.org/10.1109/ACCESS.2020.2970836>
- [63] Sha, S., Li, J., Zhang, K., Yang, Z., Wei, Z., Li, X., Zhu, X. (2020). RNN-Based Subway Passenger Flow Rolling Prediction. *IEEE Access*, 8, 15232-15240. <https://doi.org/10.1109/ACCESS.2020.2964680>
- [64] Ashour, A. S., El-Attar, A., Dey, N., El-Kader, H. A., Abd El-Naby, M. M. (2020). Long short term memory based patient-dependent model for FOG detection in Parkinson's disease. *Pattern Recognition Letters*, 131, 23-29. <https://doi.org/10.1016/j.patrec.2019.11.036>
- [65] Chen, Y. (2020). LSTM recurrent neural network prediction algorithm based on Zernike modal coefficients. *Optik*, 203, 163796. <https://doi.org/10.1016/j.ijleo.2019.163796>
- [66] Li, P., Abdel-Aty, M., ve Yuan, J. (2020). Real-time crash risk prediction on arterials based on LSTM-CNN. *Accident Analysis & Prevention*, 135, 105371. <https://doi.org/10.1016/j.aap.2019.105371>
- [67] Xing, Y., Yue, J., ve Chen, C. (2020). Interval Estimation of Landslide Displacement Prediction Based on Time Series Decomposition and Long Short-

- Term Memory Network. *IEEE Access*, 8, 3187-3196. <https://doi.org/10.1109/ACCESS.2019.2961295>
- [68] Guo, J., Xie, Z., Qin, Y., Jia, L., Wang, Y. (2019). Short-Term Abnormal Passenger Flow Prediction Based on the Fusion of SVR and LSTM. *IEEE Access*, 7, 42946-42955. <https://doi.org/10.1109/ACCESS.2019.2907739>
- [69] Zhang, Y., Gao, S., Han, J., Ban, M. (2019). Wind Speed Prediction Research Considering Wind Speed Ramp and Residual Distribution. *IEEE Access*, 7, 131873-131887. <https://doi.org/10.1109/ACCESS.2019.2940897>
- [70] Liu, S., Gu, S., ve Bao, T. (2017). An Automatic Forecasting Method for Time Series. *Chinese Journal of Electronics*, 26(3), 445-452. <https://doi.org/10.1049/cje.2017.01.011>
- [71] Li, T., Hua, M., ve Wu, X. (2020). A Hybrid CNN-LSTM Model for Forecasting Particulate Matter (PM_{2.5}). *IEEE Access*, 8, 26933-26940. <https://doi.org/10.1109/ACCESS.2020.2971348>
- [72] Bukhari, A. H., Raja, M. A. Z., Sulaiman, M., Islam, S., Shoaib, M., Kumam, P. (2020). Fractional Neuro-Sequential ARFIMA-LSTM for Financial Market Forecasting. *IEEE Access*, 8, 71326-71338. <https://doi.org/10.1109/ACCESS.2020.2985763>
- [73] Wang, X., ve Zhang, Y. (2020). Multi-Step-Ahead Time Series Prediction Method with Stacking LSTM Neural Network. *2020 3rd International Conference on Artificial Intelligence and Big Data (ICAIBD)*, 51-55. <https://doi.org/10.1109/ICAIBD49809.2020.9137492>
- [74] Lan, Y., ve Dai, Y. (2020). Urban Air Quality Prediction Based on Space-Time Optimization LSTM Model. *2020 3rd International Conference on Artificial Intelligence and Big Data (ICAIBD)*, 215-222. <https://doi.org/10.1109/ICAIBD49809.2020.9137441>
- [75] Cheng, G., Li, X., ve Yan, Y. (2019). Using Highway Connections to Enable Deep Small-footprint LSTM-RNNs for Speech Recognition. *Chinese Journal of Electronics*, 28(1), 107-112. <https://doi.org/10.1049/cje.2018.11.008>

- [76] Dai, S., Li, L., ve Li, Z. (2019). Modeling Vehicle Interactions via Modified LSTM Models for Trajectory Prediction. *IEEE Access*, 7, 38287-38296. <https://doi.org/10.1109/ACCESS.2019.2907000>
- [77] Zhao, Z., Chen, W., Wu, X., Chen, P. C. Y., Liu, J. (2017). LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68-75. <https://doi.org/10.1049/iet-its.2016.0208>
- [78] Gers, F. A., Eck, D., ve Schmidhuber, J. (2002). *Applying LSTM to Time Series Predictable Through Time-Window Approaches* (ss. 193-200). https://doi.org/10.1007/978-1-4471-0219-9_20
- [79] Wu, Y., Yuan, M., Dong, S., Lin, L., Liu, Y. (2018). Remaining useful life estimation of engineered systems using vanilla LSTM neural networks. *Neurocomputing*, 275, 167-179. <https://doi.org/10.1016/j.neucom.2017.05.063>
- [80] Miao, K., Han, T., Yao, Y., Lu, H., Chen, P., Wang, B., Zhang, J. (2020). Application of LSTM for short term fog forecasting based on meteorological elements. *Neurocomputing*, 408, 285-291. <https://doi.org/10.1016/j.neucom.2019.12.129>
- [81] Dai, Y., Lu, Z., Zhang, H., Zhan, T., Lu, J., Wang, P. (2019). A Correction Method of Environmental Meteorological Model Based on Long-Short-Term Memory Neural Network. *Earth and Space Science*, 6(11), 2214-2226. <https://doi.org/10.1029/2019EA000641>
- [82] Zhao, J., Deng, F., Cai, Y., Chen, J. (2019). Long short-term memory - Fully connected (LSTM-FC) neural network for PM2.5 concentration prediction. *Chemosphere*, 220, 486-492. <https://doi.org/10.1016/j.chemosphere.2018.12.128>
- [83] Gundu, V., ve Simon, S. P. (2021). PSO–LSTM for short term forecast of heterogeneous time series electricity price signals. *Journal of Ambient Intelligence and Humanized Computing*, 12(2), 2375-2385. <https://doi.org/10.1007/s12652-020-02353-9>
- [84] Poornima, S., ve Pushpalatha, M. (2019). Prediction of Rainfall Using Intensified LSTM Based Recurrent Neural Network with Weighted Linear Units. *Atmosphere*, 10(11), 668. <https://doi.org/10.3390/atmos10110668>

- [85] Zhang, G., Liu, H., Zhang, J., Yan, Y., Zhang, L., Wu, C., Hua, X., Wang, Y. (2019). Wind power prediction based on variational mode decomposition multi-frequency combinations. *Journal of Modern Power Systems and Clean Energy*, 7(2), 281-288. <https://doi.org/10.1007/s40565-018-0471-8>
- [86] Wang, D., Liu, Y., Luo, H., Yue, C., Cheng, S. (2017). Day-Ahead PM2.5 Concentration Forecasting Using WT-VMD Based Decomposition Method and Back Propagation Neural Network Improved by Differential Evolution. *International Journal of Environmental Research and Public Health*, 14(7), 764. <https://doi.org/10.3390/ijerph14070764>
- [87] Guo, Z., Zhao, W., Lu, H., Wang, J. (2012). Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. *Renewable Energy*, 37(1), 241-249. <https://doi.org/10.1016/j.renene.2011.06.023>
- [88] V, V., G, S. J., Resmi, R., Raphel, D. (2021). Artificial intelligence-based wind forecasting using variational mode decomposition. *Computational Intelligence*, 37(3), 1034-1046. <https://doi.org/10.1111/coin.12331>
- [89] Wang, J. Q., Du, Y., ve Wang, J. (2020). LSTM based long-term energy consumption prediction with periodicity. *Energy*, 197, 117197. <https://doi.org/10.1016/j.energy.2020.117197>
- [90] Bandara, K., Bergmeir, C., ve Hewamalage, H. (2021). LSTM-MSNet: Leveraging Forecasts on Sets of Related Time Series With Multiple Seasonal Patterns. *IEEE Transactions on Neural Networks and Learning Systems*, 32(4), 1586-1599. <https://doi.org/10.1109/TNNLS.2020.2985720>
- [91] Nava, N., Matteo, T., ve Aste, T. (2018). Financial Time Series Forecasting Using Empirical Mode Decomposition and Support Vector Regression. *Risks*, 6(1), 7. <https://doi.org/10.3390/risks6010007>
- [92] Li, W., Quan, C., Wang, X., Zhang, S. (2018). Short-Term Power Load Forecasting Based on a Combination of VMD and ELM. *Polish Journal of Environmental Studies*, 27(5), 2143-2154. <https://doi.org/10.15244/pjoes/78244>
- [93] Li, G., Ma, X., ve Yang, H. (2018). A Hybrid Model for Forecasting Sunspots Time Series Based on Variational Mode Decomposition and Backpropagation

- Neural Network Improved by Firefly Algorithm. *Computational Intelligence and Neuroscience*, 2018, 1-9. <https://doi.org/10.1155/2018/3713410>
- [94] Zhang, G., Ren, T., ve Yang, Y. (2020). A New Unified Deep Learning Approach with Decomposition-Reconstruction-Ensemble Framework for Time Series Forecasting.
- [95] Awajan, A., ve Alwadi, S. (2017). A HYBRID APPROACH EMD-MA FOR SHORT-TERM FORECASTING OF DAILY STOCK MARKET TIME SERIES DATA. *Journal of Internet Banking and Commerce*, 22, 1-10.
- [96] Wang, J.-N., Du, J., Jiang, C., Lai, K.-K. (2019). Chinese Currency Exchange Rates Forecasting with EMD-Based Neural Network. *Complexity*, 2019, 1-15. <https://doi.org/10.1155/2019/7458961>
- [97] Bisoi, R., Dash, P. K., ve Mishra, S. P. (2019). Modes decomposition method in fusion with robust random vector functional link network for crude oil price forecasting. *Applied Soft Computing*, 80, 475-493. <https://doi.org/10.1016/j.asoc.2019.04.026>
- [98] Niu, H., ve Xu, K. (2020). A hybrid model combining variational mode decomposition and an attention-GRU network for stock price index forecasting. *Mathematical Biosciences and Engineering*, 17(6), 7151-7166. <https://doi.org/10.3934/mbe.2020367>
- [99] Seo, Y., Kim, S., ve Singh, V. P. (2018). Comparison of different heuristic and decomposition techniques for river stage modeling. *Environmental Monitoring and Assessment*, 190(7), 392. <https://doi.org/10.1007/s10661-018-6768-2>
- [100] Yin, J., Deng, Z., Ines, A. V. M., Wu, J., ve Rasu, E. (2020). Forecast of short-term daily reference evapotranspiration under limited meteorological variables using a hybrid bi-directional long short-term memory model (Bi-LSTM). *Agricultural Water Management*, 242, 106386. <https://doi.org/10.1016/j.agwat.2020.106386>
- [101] Islam, M. S., ve Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. *Soft Computing Letters*, 3, 100009. <https://doi.org/10.1016/j.socl.2020.100009>

- [102] Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., Lin, Q. (2020). Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188. <https://doi.org/10.1016/j.jhydrol.2020.125188>
- [103] ArunKumar, K. E., Kalaga, D. v., Kumar, Ch. M. S., Kawaji, M., Brenza, T. M. (2021). Forecasting of COVID-19 using deep layer Recurrent Neural Networks (RNNs) with Gated Recurrent Units (GRUs) and Long Short-Term Memory (LSTM) cells. *Chaos, Solitons & Fractals*, 146, 110861. <https://doi.org/10.1016/j.chaos.2021.110861>
- [104] Zhang, Y., Pan, G., Chen, B., Han, J., Zhao, Y., Zhang, C. (2020). Short-term wind speed prediction model based on GA-ANN improved by VMD. *Renewable Energy*, 156, 1373-1388. <https://doi.org/10.1016/j.renene.2019.12.047>
- [105] Sajjad, M., Khan, Z. A., Ullah, A., Hussain, T., Ullah, W., Lee, M. Y., Baik, S. W. (2020). A Novel CNN-GRU-Based Hybrid Approach for Short-Term Residential Load Forecasting. *IEEE Access*, 8, 143759-143768. <https://doi.org/10.1109/ACCESS.2020.3009537>
- [106] Istiaque Sunny, Md. A., Maswood, M. M. S., Alharbi, A. G. (2020). Deep Learning-Based Stock Price Prediction Using LSTM and Bi-Directional LSTM Model. *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)*, 87-92. <https://doi.org/10.1109/NILES50944.2020.9257950>
- [107] Alencar, D. B., Affonso, C. M., Oliveira, R. C. L., Filho, J. C. R. (2018). Hybrid Approach Combining SARIMA and Neural Networks for Multi-Step Ahead Wind Speed Forecasting in Brazil. *IEEE Access*, 6, 55986-55994. <https://doi.org/10.1109/ACCESS.2018.2872720>
- [108] Li, Y., Chen, X., Li, C., Tang, G., Gan, Z., An, X. (2021). A Hybrid Deep Interval Prediction Model for Wind Speed Forecasting. *IEEE Access*, 9, 7323-7335. <https://doi.org/10.1109/ACCESS.2020.3047903>
- [109] Moreno, S. R., Mariani, V. C., ve Coelho, L. dos S. (2021). Hybrid multi-stage decomposition with parametric model applied to wind speed forecasting in

- Brazilian Northeast. *Renewable Energy*, 164, 1508-1526. <https://doi.org/10.1016/j.renene.2020.10.126>
- [110] Zhu, Q., Zhang, F., Liu, S., Wu, Y., Wang, L. (2019). A hybrid VMD–BiGRU model for rubber futures time series forecasting. *Applied Soft Computing*, 84, 105739. <https://doi.org/10.1016/j.asoc.2019.105739>
- [111] Xie, Q., Song, L., He, Y., Dang, P. (2020). Short-term Wind Power Prediction Model Based on GSA Optimized GRU Neural Network. *2020 IEEE International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA)*, 581-585. <https://doi.org/10.1109/ICIBA50161.2020.9277119>
- [112] Inteha, A., ve Nahid-Al-Masood. (2021). A GRU-GA Hybrid Model Based Technique for Short Term Electrical Load Forecasting. *2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*, 515-519. <https://doi.org/10.1109/ICREST51555.2021.9331156>
- [113] Xiuyun, G., Ying, W., Yang, G., Chengzhi, S., Wen, X., Yimiao, Y. (2018). Short-term Load Forecasting Model of GRU Network Based on Deep Learning Framework. *2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2)*, 1-4. <https://doi.org/10.1109/EI2.2018.8582419>
- [114] Li, X., Xu, X., Wang, J., Li, J., Qin, S., Yuan, J. (2020). Study on Prediction Model of HIV Incidence Based on GRU Neural Network Optimized by MHPSO. *IEEE Access*, 8, 49574-49583. <https://doi.org/10.1109/ACCESS.2020.2979859>
- [115] Jia, P., Liu, H., Wang, S., Wang, P. (2020). Research on a Mine Gas Concentration Forecasting Model Based on a GRU Network. *IEEE Access*, 8, 38023-38031. <https://doi.org/10.1109/ACCESS.2020.2975257>
- [116] DHMİ. (2006). *Devlet Hava Meydanları İşletmesi Meteoroloji Ders Kitabı*. Ankara.
- [117] ESTÜ. (2022). Havacılık ve Uzay Bilimleri Fakültesi Pilotaj Bölümü Program Profili. <https://akts.eskisehir.edu.tr/tr/program/programProfili/325/8/1> (Erişim tarihi: 29.05.2022)
- [118] DHMİ. (2019). *Havacılık Enformasyon Yayını (AIP)*. Ankara.


- [119] ICAO. (2007). *Meteorological Service for International Air Navigation (Annex 3)*.
- [120] ICAO. (2007). *Aerodrome Design and Operations (Annex 14)*.
- [121] Textron Company. (1998). *Cessna 172S pilot operating manual*.
- [122] E. Socata. (1988). *TB20 pilots's information manual*.
- [123] Simon Kennedy. (2009). *Python Astral Library*. <https://github.com/sffjunkie/astral> (Erişim tarihi: 18.05.2018)
- [124] Dragomiretskiy, K., ve Zosso, D. (2014). Variational Mode Decomposition. *IEEE Transactions on Signal Processing*, 62(3), 531–544. <https://doi.org/10.1109/TSP.2013.2288675>
- [125] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C., Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London Series A*, 454(1971), 903–998. <https://doi.org/10.1098/rspa.1998.0193>
- [126] Nathaniel, E. U., George, N. J., ve Etuk, S. E. (2013). Determination of Instantaneous Frequencies of Low Plasma Waves in the Magnetosheath Using Empirical Mode Decomposition (EMD) and Hilbert Transform (HT). *Atmospheric and Climate Sciences*, 03(04), 576–580. <https://doi.org/10.4236/acs.2013.34060>
- [127] Kahaner, D., Moler, C. B., Nash, S. G., Forsythe, G. E. (George E. (1989). *Numerical methods and software / David Kahaner, Cleve Moler, Stephen Nash*. Prentice-Hall.
- [128] Fritsch, F. N., ve Carlson, R. E. (1980). Monotone Piecewise Cubic Interpolation. *SIAM Journal on Numerical Analysis*, 17(2), 238–246. <https://doi.org/10.1137/0717021>
- [129] Rabbath, C. A., ve Corriveau, D. (2019). A comparison of piecewise cubic Hermite interpolating polynomials, cubic splines and piecewise linear functions for the approximation of projectile aerodynamics. *Defence Technology*, 15(5), 741–757. <https://doi.org/10.1016/j.dt.2019.07.016>

- [130] Nazari, M., ve Sakhaei, S. M. (2020). Successive variational mode decomposition. *Signal Processing*, 174, 107610. <https://doi.org/10.1016/j.sigpro.2020.107610>
- [131] Zhang, Y., Pan, G., Chen, B., Han, J., Zhao, Y., Zhang, C. (2020). Short-term wind speed prediction model based on GA-ANN improved by VMD. *Renewable Energy*, 156, 1373–1388. <https://doi.org/10.1016/j.renene.2019.12.047>
- [132] Blackledge, J. M. (2006). *Digital signal processing (2nd ed.)*. Horwood Publishing.
- [133] Feldman, M. (2011). *Hilbert Transform Applications in Mechanical Vibration*. Wiley. <https://doi.org/10.1002/9781119991656>
- [134] Boyd, S. (2010). Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers. *Foundations and Trends® in Machine Learning*, 3(1), 1–122. <https://doi.org/10.1561/22000000016>
- [135] Parikh, N. (2014). Proximal Algorithms. *Foundations and Trends® in Optimization*, 1(3), 127–239. <https://doi.org/10.1561/24000000003>
- [136] Han, Z., Zhao, J., Leung, H., Ma, K. F., Wang, W. (2021). A Review of Deep Learning Models for Time Series Prediction. *IEEE Sensors Journal*, 21(6), 7833–7848. <https://doi.org/10.1109/JSEN.2019.2923982>
- [137] Allison, S., Bai, H., ve Jayaraman, B. (2020). Wind estimation using quadcopter motion: A machine learning approach. *Aerospace Science and Technology*, 98, 105699. <https://doi.org/10.1016/j.ast.2020.105699>
- [138] PyTorch. (2021). Pytorch Documentation. <https://pytorch.org/docs/stable/nn.html#recurrent-layers> (Erişim tarihi: 18.05.2022)
- [139] DiDL. (2021). Dive into Deep Learning Documentation. https://d2l.ai/chapter_recurrent-modern/index.html (Erişim tarihi: 18.05.2022)
- [140] Bengio, Y. (2016). *Deep Learning*. MIT Press.
- [141] Hochreiter, S., ve Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

- [142] Cho, K., van Merriënboer, B., Bahdanau, D., Bengio, Y. (2014). *On the Properties of Neural Machine Translation: Encoder-Decoder Approaches*.
- [143] Chung, J., Gulcehre, C., Cho, K., Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. <https://doi.org/10.48550/arXiv.1412.3555>
- [144] Keskar, N. S., ve Socher, R. (2017). Improving Generalization Performance by Switching from Adam to SGD. <https://doi.org/10.48550/arXiv.1712.07628>
- [145] Landro, N., Gallo, I., ve la Grassa, R. (2021). Combining Optimization Methods Using an Adaptive Meta Optimizer. *Algorithms*, 14(6), 186. <https://doi.org/10.3390/a14060186>


EKLER

EK-1 Hasan Polatkan Havalimanı Meydan Krokisi




Şekil Hasan Polatkan Havalimanı (LTBY) meydan krokisi


EK-2 Hata Ölçütlerinde Önerilen Model



Şekil sMAPE ölçütünde SMM tahminleri




Şekil RMSE ölçütünde SMM tahminleri




Şekil MAE ölçütünde SMM tahminleri


EK-3 Farklı Kategorilerdeki Grbz Modellerde Ait Kiviat Diagramları



(a) sMAPE




(b) RMSE




(c) MAE


Şekil (a) sMAPE, (b) RMSE ve (c) MAE ölçtlerinde normalize sonular (VMD3T)



(a) sMAPE




(b) RMSE




(c) MAE


Şekil (a) sMAPE, (b) RMSE ve (c) MAE ölçtlerinde normalize sonular (EMDs1T)



(a) sMAPE



(b) RMSE



(c) MAE

Şekil (a) sMAPE, (b) RMSE ve (c) MAE ölçtlerinde normalize sonular (EMDp1T)

EK-4 Uçuşa Elverişli Günlerin Dağılımı

Tablo Uçuşa elverişli gün dağılımı (günlük en az 3 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	24	22	28	30	31	30	29	31	29	30	25	27
2010	19	21	27	13	31	24	30	29	30	28	22	21
2011	18	26	27	30	30	29	31	30	29	27	29	28
2012	19	17	24	24	30	30	31	31	27	31	22	18
2013	24	26	30	27	31	30	30	31	30	28	29	25
2014	20	27	28	29	29	29	31	30	28	29	24	22
2015	17	22	29	29	26	29	31	31	29	29	30	17
2016	22	27	26	28	30	30	31	28	30	30	25	22
2017	16	21	30	26	30	27	31	30	30	28	25	24
2018	20	23	28	30	30	30	31	31	29	29	25	15
2019	18	23	30	25	28	30	30	31	30	30	27	12
2020	21	22	27	30	28	30	31	31	29	28	30	26
μ	19,8	23,0	27,8	26,7	29,5	29,0	30,5	30,3	29,1	28,9	26,0	21,4

Tablo Uçuşa elverişli gün dağılımı (günlük en az 4 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	23	20	26	29	30	30	28	31	29	30	25	25
2010	18	19	26	13	31	23	29	20	28	26	21	21
2011	17	25	27	30	28	28	30	29	28	27	28	26
2012	19	16	22	23	30	29	27	30	27	31	21	16
2013	24	26	29	26	30	30	30	30	29	28	27	24
2014	19	27	28	29	27	26	31	26	28	27	24	19
2015	16	21	29	29	26	25	29	31	26	27	29	15
2016	21	26	26	28	30	26	30	27	29	30	25	22
2017	13	21	29	25	30	25	27	28	26	27	25	23
2018	18	22	26	30	30	30	30	29	28	29	23	13
2019	16	21	30	24	27	29	28	28	30	30	26	10
2020	18	21	27	30	28	30	31	30	25	28	28	24
μ	18,5	22,0	27,0	26,3	28,9	27,5	29,1	28,2	27,7	28,3	25,1	19,8

Tablo Uçuşa elverişli gün dağılımı (günlük en az 5 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	20	20	24	29	30	27	21	27	28	29	24	25
2010	17	18	26	12	26	19	22	6	24	23	21	20
2011	17	23	25	25	27	28	21	26	25	26	27	26
2012	18	12	21	23	30	26	15	26	26	31	20	16
2013	22	25	27	26	29	24	25	27	27	27	26	22
2014	17	27	27	29	26	24	22	13	25	25	21	16
2015	14	19	27	28	26	24	22	21	21	27	29	14
2016	14	25	26	27	28	22	24	21	24	30	25	20
2017	12	19	28	24	30	23	21	21	18	25	23	22
2018	16	22	26	30	28	29	28	21	24	29	23	12
2019	15	20	30	23	26	28	22	18	30	29	26	10
2020	18	19	27	29	27	30	25	21	19	26	28	23
μ	16,6	20,7	26,1	25,4	27,7	25,3	22,3	20,6	24,2	27,2	24,4	18,8

Tablo Uçuşa elverişli gün dağılımı (günlük en az 6 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	17	20	23	29	29	25	17	24	27	29	24	22
2010	16	16	25	11	22	14	15	3	16	22	21	18
2011	17	21	24	25	25	25	15	21	20	24	26	23
2012	15	10	21	23	30	21	10	18	20	28	19	14
2013	19	23	24	24	26	23	21	15	27	27	25	20
2014	15	26	24	29	25	21	14	9	23	25	18	12
2015	11	18	25	27	26	23	20	13	11	25	29	12
2016	14	25	25	26	24	20	18	15	21	29	25	18
2017	11	19	27	23	26	19	18	18	15	24	21	20
2018	16	22	23	29	27	27	16	10	21	29	22	9
2019	12	19	29	21	24	24	20	12	26	27	23	9
2020	17	18	26	29	20	28	16	14	12	26	28	21
μ	15,0	19,7	24,6	24,6	25,3	22,5	16,6	14,3	19,9	26,2	23,4	16,5

Tablo Uçuşa elverişli gün dağılımı (günlük en az 7 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	14	18	22	28	27	18	15	18	26	27	20	18
2010	11	14	24	10	20	13	9	3	10	18	21	16
2011	14	18	24	24	22	22	8	15	14	23	22	18
2012	14	6	19	22	26	15	8	15	12	26	17	12
2013	15	20	24	23	25	21	20	6	26	25	21	18
2014	12	24	23	28	21	18	11	5	17	24	18	11
2015	10	15	25	27	25	21	15	5	4	22	23	11
2016	13	25	24	26	21	15	12	8	20	29	25	18
2017	10	18	26	22	20	13	11	10	14	22	20	17
2018	16	20	20	29	25	23	9	4	17	27	17	8
2019	11	17	29	20	21	20	16	7	21	22	22	7
2020	15	17	25	28	18	22	11	8	7	24	26	20
μ	12,9	17,6	23,7	23,9	22,5	18,4	12,0	8,67	15,6	24,0	21,0	14,5

Tablo Uçuşa elverişli gün dağılımı (günlük en az 8 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	12	14	19	27	25	12	10	11	22	23	13	16
2010	8	12	23	9	19	11	5	0	7	17	18	11
2011	13	14	22	22	19	18	3	10	9	20	17	14
2012	8	3	17	21	22	13	6	12	11	22	12	12
2013	14	20	24	22	19	17	14	3	25	24	19	14
2014	10	23	23	27	21	14	8	3	14	21	15	8
2015	9	15	24	27	20	21	15	4	2	17	20	11
2016	7	24	20	24	20	13	10	4	16	28	24	13
2017	8	15	23	19	18	12	11	7	11	21	16	16
2018	15	17	19	28	25	16	5	3	15	24	14	7
2019	11	17	27	20	18	16	13	6	17	18	19	7
2020	12	15	24	28	14	14	9	4	5	20	22	18
μ	10,5	15,7	22,0	22,8	20,0	14,7	9,08	5,58	12,8	21,2	17,4	12,2

Tablo Uçuşa elverişli gün dağılımı (günlük en az 9 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	10	12	18	27	22	10	7	7	21	20	10	14
2010	6	11	21	8	16	9	3	0	6	13	16	10
2011	10	9	19	20	16	12	3	4	7	19	14	8
2012	3	3	15	19	20	11	4	7	10	17	10	10
2013	12	18	23	18	15	13	9	1	22	19	19	11
2014	10	22	21	25	20	12	7	1	11	16	12	5
2015	9	10	18	27	17	19	12	4	1	12	19	8
2016	6	18	19	24	16	8	7	1	14	26	19	9
2017	4	14	21	19	17	9	8	7	10	20	14	14
2018	11	14	19	23	16	11	4	1	11	23	11	5
2019	9	16	25	19	15	10	11	4	13	16	16	6
2020	7	13	24	24	12	8	9	4	2	18	16	12
μ	8,08	13,3	20,2	21,0	16,8	11,0	7,00	3,42	10,6	18,2	14,6	9,33

Tablo Uçuşa elverişli gün dağılımı (günlük en az 10 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	6	7	15	26	19	7	2	5	16	17	9	8
2010	4	9	20	8	14	4	2	0	4	10	13	6
2011	5	7	18	16	13	10	3	3	5	16	8	7
2012	2	3	15	16	13	8	4	3	7	11	7	8
2013	11	16	19	17	12	10	7	1	18	17	15	8
2014	7	19	20	21	18	10	3	1	10	12	10	4
2015	7	8	16	25	14	14	9	2	1	10	15	5
2016	5	15	18	23	14	7	2	1	12	19	12	7
2017	2	11	17	17	16	7	4	5	8	18	14	9
2018	9	11	15	23	13	10	0	0	11	17	10	3
2019	8	13	24	19	9	6	7	2	9	12	12	6
2020	5	11	22	23	10	5	7	2	2	11	10	8
μ	5,92	10,8	18,2	19,5	13,7	8,17	4,17	2,08	8,58	14,1	11,2	6,58

Tablo Uçuşa elverişli gün dağılımı (günlük en az 11 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	5	5	12	24	18	5	1	1	14	14	7	7
2010	3	6	20	8	14	3	2	0	4	8	12	6
2011	4	3	15	15	13	8	2	3	5	14	6	4
2012	2	2	11	12	10	6	4	3	4	10	6	5
2013	10	13	15	16	7	5	6	1	15	15	13	8
2014	5	14	17	18	16	8	2	0	9	8	9	1
2015	7	5	15	24	11	10	8	2	0	7	11	1
2016	2	10	18	20	13	7	2	1	10	15	6	2
2017	1	9	16	16	13	6	2	4	7	17	11	7
2018	5	10	14	22	9	7	0	0	8	13	8	1
2019	5	13	23	16	7	6	4	2	6	7	11	6
2020	4	7	18	23	10	3	4	1	2	9	5	5
μ	4,42	8,08	16,1	17,8	11,7	6,17	3,08	1,50	7,00	11,4	8,75	4,42

Tablo Uçuşa elverişli gün dağılımı (günlük en az 12 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	0	4	7	21	15	3	1	1	12	6	0	0
2010	0	5	14	6	13	1	1	0	3	7	0	0
2011	0	3	10	15	12	7	0	1	3	9	0	0
2012	0	2	11	9	7	4	1	3	2	7	0	0
2013	0	11	11	13	4	4	6	0	12	10	0	0
2014	0	7	15	14	16	5	2	0	7	6	0	0
2015	0	4	12	21	10	8	4	1	0	5	0	0
2016	0	6	17	18	11	5	0	1	7	10	0	0
2017	0	4	14	15	12	5	1	2	6	14	0	0
2018	0	7	12	19	9	6	0	0	6	8	0	0
2019	0	6	18	14	7	4	2	2	3	2	0	0
2020	0	2	14	21	10	3	1	0	2	6	0	0
μ	0,00	5,08	12,9	15,5	10,5	4,58	1,58	0,92	5,25	7,50	0,00	0,00

Tablo Uçuşa elverişli gün dağılımı (günlük en az 13 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	0	0	5	18	15	3	1	0	7	2	0	0
2010	0	0	10	5	11	1	1	0	1	5	0	0
2011	0	0	10	10	8	6	0	1	3	3	0	0
2012	0	0	10	8	5	3	0	3	1	4	0	0
2013	0	0	6	11	3	4	6	0	10	5	0	0
2014	0	0	9	10	16	4	2	0	5	3	0	0
2015	0	0	4	19	10	5	4	1	0	1	0	0
2016	0	0	11	15	10	4	0	1	5	1	0	0
2017	0	0	7	14	11	5	1	2	6	6	0	0
2018	0	0	8	16	6	3	0	0	6	4	0	0
2019	0	0	13	12	7	3	2	1	2	0	0	0
2020	0	0	8	21	8	3	0	0	0	3	0	0
μ	0,00	0,00	8,42	13,2	9,17	3,67	1,42	0,75	3,83	3,08	0,00	0,00

Tablo Uçuşa elverişli gün dağılımı (günlük en az 14 saat içeren)

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
2009	0	0	1	15	13	2	0	0	0	0	0	0
2010	0	0	0	1	5	0	1	0	1	0	0	0
2011	0	0	1	7	5	5	0	0	0	0	0	0
2012	0	0	0	6	2	2	0	2	0	0	0	0
2013	0	0	1	9	2	1	5	0	2	0	0	0
2014	0	0	0	8	13	4	1	0	0	0	0	0
2015	0	0	0	14	10	3	3	0	0	0	0	0
2016	0	0	2	12	8	3	0	1	0	0	0	0
2017	0	0	0	11	9	3	1	2	0	0	0	0
2018	0	0	1	15	4	2	0	0	0	0	0	0
2019	0	0	0	9	6	2	2	0	0	0	0	0
2020	0	0	0	19	7	3	0	0	0	0	0	0
μ	0,00	0,00	0,50	10,5	7,00	2,50	1,08	0,42	0,25	0,00	0,00	0,00

ÖZGEÇMİŞ

ORCID NO: 0000-0001-8925-8312

Adı-Soyadı: Ali TATLI

Yabancı Dil: İngilizce

Doğum Yeri ve Yılı: -

E-Posta: -

Eğitim ve Mesleki Geçmişi:

- 2010, Erciyes Üniversitesi [Lisans], Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü
- 2012, Araştırma Görevlisi, Erzincan Üniversitesi, Ali Cavit Çelebioğlu Sivil Havacılık Yüksekokulu
- 2014, Araştırma Görevlisi, Anadolu Üniversitesi, Havacılık ve Uzak Bilimleri Fakültesi
- 2016, Anadolu Üniversitesi [Yüksek Lisans], Fen Bilimleri Enstitüsü, Havacılık Elektrik ve Elektronik Anabilim dalı
- 2018, Araştırma Görevlisi, Eskişehir Teknik Üniversitesi, Havacılık ve Uzak Bilimleri Fakültesi

Yayınlar:

- Tatlı, A., ve Kahvecioğlu, S. (2016). NARX neural networks based time series prediction for amount of airworthiness time. *2016 National Conference on Electrical, Electronics and Biomedical Engineering (ELECO)*, 130–134.
- Sarıbaş, H., Tatlı, A., ve Onrat, A. (2018, May). Control of unmanned aerial vehicles using self tuning fuzzy PID. *Proceeding 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Tatlı, A., Kahvecioğlu, S., Karakoç, H. (2020). Time-Series Prediction for Amount of Airworthiness Based on Time-Delay Neural Networks. *Elektronika Ir Elektrotehnika*, 26(5), 28–32. <https://doi.org/10.5755/j01.eie.26.5.25843>

- Tatlı, A., Süzer A. E., Filik T., ve Karakoç T. H. (2021). A case study on investigating probabilistic characteristics of wind speed data for green airport. *International Symposium on Aircraft Technology, MRO&Operations 2021*, Budapest, Hungary, 28 June 2021
- Tatlı, A., Böcü, E., Filik, T., ve Karakoç, T. H. (2022). A case study on the effect of meteorological events on the efficiency of flight training organization. *Aircraft Engineering and Aerospace Technology*, 94(7), 1109–1116. <https://doi.org/10.1108/AEAT-10-2021-0295>

