KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

# KOMPLEKS-DEĞERLİ VERİLER KULLANILARAK DERİN ÖĞRENME YÖNTEMLERİ İLE RÜZGAR HIZI VE YÖNÜ TAHMİNİ

YÜKSEK LİSANS TEZİ

YUNUS DUYAR

DANIŞMANLAR
PROF. DR. ENGİN CEMAL MENGÜÇ
DR. ÖĞR. ÜYESİ ALPER EMLEK

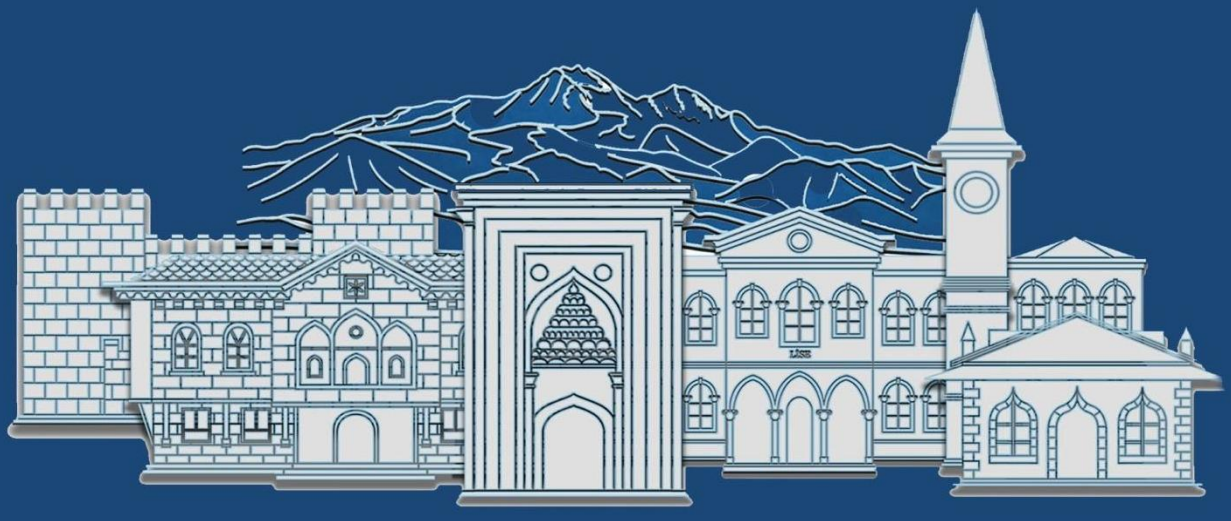

2025

**T.C.**
**KAYSERİ ÜNİVERSİTESİ**
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**
**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

# KOMPLEKS-DEĞERLİ VERİLER KULLANILARAK DERİN ÖĞRENME YÖNTEMLERİ İLE RÜZGAR HIZI VE YÖNÜ TAHMİNİ

**(Yüksek Lisans Tezi)**

**Hazırlayan**
**Yunus DUYAR**

**Danışmanlar**
**Prof. Dr. Engin Cemal MENGÜÇ**
**Dr. Öğr. Üyesi Alper EMLEK**

**Jüri Üyeleri**
**Prof. Dr. Engin Cemal MENGÜÇ**
**Doç. Dr. Rıdvan DEMİR**
**Dr. Öğr. Üyesi Recep YILDIZ**

**Haziran 2025**
**KAYSERİ**

# BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Yunus DUYAR

| | TEZ İNTİHAL RAPORU TESLİM FORMU | Doküman No | FR-287 |
|---|---|---|---|
| | | İlk Yayın Tarihi | 8/02/2022 |
| | | Revizyon Tarihi | - |
| | | Revizyon No | 0 |
| | | Sayfa No | 1/1 |

**T.C.**
**Kayseri Üniversitesi**
**Lisansüstü Eğitim Enstitüsü Müdürlüğü**

Anabilim Dalı : Elektrik-Elektronik Mühendisliği
Program Adı : Yüksek Lisans
Tez Başlığı : Kompleks-Değerli Veriler Kullanılarak Derin Öğrenme Yöntemleri ile Rüzgar Hızı ve Yönü Tahmini

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 50 sayfalık kısmına ilişkin 04/06/2025 tarihinde ***Turnitin*** intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı**: %7'**dir.

Uygulanan filtrelemeler:

1- Giriş dahil
2- Ana Bölümler dahil
3- Sonuç dahil
4- Alıntılar dahil
5- Kapak hariç
6- Önsöz ve Teşekkür hariç
7- İçindekiler hariç
8- Kaynakça hariç
9- Özet hariç
10- Yedi (7) kelimeden daha az örtüşme içeren metin kısımları hariç

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Önerisi Hazırlama, Tez Yazma ve Teslim Yönergesini inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 04/06/2025

Danışman — Öğrenci

Prof. Dr. Engin Cemal MENGÜÇ — Yunus DUYAR

# KILAVUZA UYGUNLUK

Kompleks-Değerli Veriler Kullanılarak Derin Öğrenme Yöntemleri ile Rüzgar Hızı ve Yönü Tahmini başlıklı Yüksek Lisans tezi, Kayseri Üniversitesi Lisansüstü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır.

| **Tezi Hazırlayan** | **Tez Danışmanı** |
| --- | --- |
| Yunus DUYAR | Prof. Dr. Engin Cemal MENGÜÇ |

**Elektrik-Elektronik Mühendisliği ABD Başkanı**

Prof. Dr. Engin Cemal MENGÜÇ

# KABUL VE ONAY TUTANAĞI

Prof. Dr. Engin Cemal MENGÜÇ danışmanlığında Yunus DUYAR tarafından hazırlanan "Kompleks-Değerli Veriler Kullanılarak Derin Öğrenme Yöntemleri ile Rüzgar Hızı ve Yönü Tahmini" başlıklı bu çalışma jürimiz tarafından Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

19 / 06 /2025

## JÜRİ:

Danışman **: Prof. Dr. Engin Cemal MENGÜÇ**

Üye **: Doç. Dr. Rıdvan DEMİR**

Üye **: Dr. Öğr. Üyesi Recep YILDIZ**

## ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun ……...…… tarih ve …… sayılı kararı ile onaylanmıştır.

……. /……../ ……

**Doç. Dr. Ahmet TERZİ**

Enstitü Müdürü

# ÖN SÖZ / TEŞEKKÜR

Bu tez çalışmasının ana fikrini ortaya koyan ve bu noktaya gelmesinde büyük pay sahibi olan, yüksek lisans eğitimim boyunca bilgi ve tecrübesini hiçbir zaman esirgemeyen ve her durum ve şartta desteğini eksiksiz hissettiren danışmanım sayın Prof. Dr. Engin Cemal MENGÜÇ'e ve Dr. Öğr. Üyesi Alper EMLEK teşekkürü bir borç bilirim. Yüksek lisans eğitimim ve tez çalışmam boyunca eşsiz yol göstericiliğiyle ufkumu açan, kıymetli destekleriyle bu süreci verimli kılan ve aynı ekibin parçası olmaktan kıvanç duyduğum Sayın Arş. Gör. Yusuf Eren teşekkürlerimi sunarım. Öte yandan, araştırmalarım için çalışma ortamı sunan ve beni destekleyen Kayseri Üniversitesi Mühendislik, Mimarlık ve Tasarım Fakültesinin idari ve akademik personellerine ve değerli bilgilerinden faydalandığım, özel ilgi ve alakalarını yakından hissettiğim Kayseri Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünün kıymetli öğretim üyelerine teşekkür ederim.

Son olarak girdiğim bu yolda bir an bile beni yalnız bırakmayan, sevgi ve desteklerini her daim hissettiğim sevgili aileme bu tezi ithaf etmekle birlikte sonsuz sevgi ve teşekkürlerimi sunarım.

**Yunus DUYAR, Kayseri, 2025**

# KOMPLEKS-DEĞERLİ VERİLER KULLANILARAK DERİN ÖĞRENME YÖNTEMLERİ İLE RÜZGAR HIZI VE YÖNÜ TAHMİNİ

**Yunus DUYAR**

**Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü**
**Yüksek Lisans, Haziran 2025**
**Danışman: Prof. Dr. Engin Cemal MENGÜÇ**
**İkinci Danışman: Dr. Öğr. Üyesi Alper EMLEK**

## ÖZET

Bu tez çalışmasında, kısa vadeli rüzgâr hızı ve yönü tahmini için kompleks-değerli sinyal temsiline dayalı bir yaklaşım önerilmiş ve bu yapının farklı derin öğrenme modelleriyle başarımı değerlendirilmiştir. Rüzgâr sinyali, genlik ve faz bileşenleriyle kompleks düzlemde ifade edilerek, klasik yöntemlere kıyasla daha bütüncül bir yapı sunulmuştur. Bu kapsamda MLP, 1D-CNN, LSTM, BiLSTM, GRU ve 1D-CNN+LSTM olmak üzere altı farklı model iki ayrı zaman dilimine ait veri kümeleriyle test edilmiştir. Modellerin eğitim başarımları; standart tahmin kazancı, korelasyon katsayısı ve kayıp fonksiyonu gibi metrikler üzerinden değerlendirilmiştir.

Elde edilen bulgulara göre, BiLSTM modeli hem hız hem yön tahmininde en yüksek doğruluğa ve en düşük kayıp değerine ulaşmıştır. LSTM ve 1D-CNN modelleri de eğitim süresi ve performans açısından etkili sonuçlar vermiştir. MLP modeli ise kısa eğitim süresine rağmen düşük doğrulukla sınırlı kalmıştır.

Bu çalışma, kompleks-değerli sinyal temsiline dayalı yapıların derin öğrenme modelleri ile entegrasyonunun, rüzgâr tahmini gibi yönlü büyüklüklerde yüksek doğruluk sunduğunu ortaya koymuştur. Elde edilen sonuçlar, söz konusu modellerin yenilenebilir enerji sistemleri ve yenilenebilir enerji kaynaklarının entegrasyonu gibi alanlarda etkin şekilde kullanılabileceğini göstermektedir.

**Anahtar Kelimeler:** Rüzgâr tahmini, rüzgâr hızı ve yönü, derin öğrenme, kompleks-değerli sinyal işleme

# PREDICTION OF WIND SPEED AND DIRECTION WITH DEEP LEARNING METHODS USING COMPLEX-VALUED DATA

**Yunus DUYAR**

**Kayseri University Institute of Graduate Education**
**Master Thesis, June 2025**
**Thesis Advisor: Prof. Dr. Engin Cemal MENGÜÇ**
**Second Advisor: Assist. Prof. Dr. Alper EMLEK**

## ABSTRACT

In this thesis, a complex-valued signal representation-based approach is proposed for short-term wind speed and direction forecasting, and the performance of different deep learning models is evaluated. The wind signal is represented holistically on the complex plane using magnitude and phase components, offering a more integrated modeling structure compared to traditional methods. In this context, six different models MLP, 1D-CNN, LSTM, BiLSTM, GRU, and a hybrid 1D-CNN+LSTM were tested on two distinct datasets corresponding to different time periods. Model performances were assessed using metrics such as standard prediction gain, correlation coefficient, and loss function.

The results show that the BiLSTM model achieved the highest prediction accuracy and the lowest loss values for both wind speed and direction. The LSTM and 1D-CNN models also delivered effective results in terms of training duration and performance. On the other hand, the MLP model exhibited limited success due to low accuracy despite its fast training process.

This study demonstrates that integrating complex-valued signal representation with deep learning architectures provides high accuracy in modeling directional meteorological variables such as wind. The findings suggest that the proposed models can be effectively utilized in renewable energy systems and integration processes of renewable energy sources.

**Keywords:** Wind forecasting, wind speed and direction, deep learning, complex-valued signal

# İÇİNDEKİLER

## KOMPLEKS-DEĞERLİ VERİLER KULLANILARAK DERİN ÖĞRENME YÖNTEMLERİ İLE RÜZGAR HIZI VE YÖNÜ TAHMİNİ

**BİLİMSEL ETİĞE UYGUNLUK..... i**
**TEZ İNTİHAL RAPORU TESLİM FORMU..... ii**
**KILAVUZA UYGUNLUK..... iii**
**KABUL VE ONAY TUTANAĞI ..... iv**
**ÖN SÖZ / TEŞEKKÜR ..... v**
**ÖZET..... vi**
**ABSTRACT ..... vii**
**İÇİNDEKİLER ..... viii**
**SİMGELER VE KISALTMALAR LİSTESİ..... x**
**TABLOLAR LİSTESİ..... xi**
**GİRİŞ ..... 1**

## BİRİNCİ BÖLÜM

## MATERYAL VE METOT

1.1. Çok Katmanlı Algılayıcı (Multilayer Perceptron - MLP) ..... 9
1.2. Tek Boyutlu Konvolüsyonel Sinir Ağı (1D-CNN) ..... 12
1.3. Uzun Kısa Süreli Bellek Ağı (Long Short-Term Memory - LSTM) ..... 16
1.4. Çift Yönlü Uzun Kısa Süreli Bellek Ağı (Bidirectional Long Short-Term Memory - BiLSTM) ..... 18
1.5. Kapı Kontrollü Tekrarlayan Birim (Gated Recurrent Unit - GRU) ..... 21

## İKİNCİ BÖLÜM

## MLP, LSTM-1DCNN, GRU, BİLSTM İLE RÜZGAR HIZI VE YÖNÜN KOMPLEKS DÜZLEMDE KESTİRİMİ

2.1. Veri Ön İşleme ..... 25

2.2. Çok Katmanlı Algılayıcı (MLP) ..... 26
2.3. Bir Boyutlu Evrişimsel Sinir Ağları (1D-CNN) ..... 27
2.4. Uzun-Kısa Süreli Bellek (LSTM) ..... 28
2.5. Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory – BiLSTM) ..... 30
2.6. Kapı Kontrollü Tekrarlayan Birim (Gated Recurrent Unit – GRU) ..... 31
2.7. 1D-CNN + LSTM Hibrit Modeli ile Rüzgâr Tahmini ..... 32

**ÜÇÜNCÜ BÖLÜM**

**BENZETİM SONUÇLARI VE TARTIŞMA**

3.1. Veri Seti ve Çalışma Ortam Tanımı ..... 34
3.2. Başarım Metrikleri ..... 35
3.3. Deneysel Sonuçlar ..... 36
3.4. Çok Katmanlı Algılayıcı (MLP) Modeli ile Kompleks-Değerli Rüzgâr Tahmin Performansı ..... 38
3.5. Tek Boyutlu Konvolüsyonel Sinir Ağı (1D-CNN) Modeli ile Kompleks-Değerli Rüzgâr Tahmin Performansı ..... 42
3.6. Uzun Kısa Süreli Bellek (LSTM) Ağı ile Kompleks-Değerli Rüzgâr Tahmin Performansı ..... 46
3.7. Çift Yönlü LSTM (BiLSTM) Ağı ile Kompleks-Değerli Rüzgâr Tahmin Performansı ..... 50
3.8. Kapı Kontrollü Tekrarlayan Birim (GRU) Ağı ile Kompleks-Değerli Rüzgâr Tahmin Performansı ..... 53
3.9. Tek Boyutlu Konvolüsyonel Sinir Ağı ve LSTM (1D-CNN + LSTM) Hibrit Modeli ile Kompleks-Değerli Rüzgâr Tahmin Performansı ..... 57

**DÖRDÜNCÜ BÖLÜM**

**SONUÇ**

**KAYNAKÇA ..... 63**
**TEZ İNTİHAL RAPORU ..... 70**
**ÖZGEÇMİŞ ..... 77**

# SİMGELER VE KISALTMALAR LİSTESİ

**Kısaltmalar**

MLP : Çok katmanlı algılayıcı (Multilayer Perceptron)

ReLU : Doğrultulmuş doğrusal birim (Rectified Linear Unit)

CNN : Evrişimli sinir ağı (Convolutional Neural Network)

GRU : Kapı kontrollü tekrarlayan birim (Gated Recurrent Unit)

CC : Korelasyon katsayısı (Correlation Coefficient)

AWOS : Otomatik meteoroloji gözlem sistemi (Automated Weather Observing System)

ARIMA : Otoregresif bütünleşik hareketli ortalama (Autoregressive Integrated Moving Average)

NWP : Sayısal hava tahmini (Numerical Weather Prediction)

FIR : Sonlu dürtü cevabı (Finite Impulse Response)

IIR : Sonsuz dürtü cevabı (Infinite Impulse Response)

Rp : Standart tahmin kazancı (Standard Prediction Gain)

1DCNN : Tek boyutlu evrişimsel sinir ağı (One-Dimensional Convolutional Neural Network)

RNN : Tekrarlayan sinir ağı (Recurrent Neural Network)

Adam : Uyarlanabilir moment tahmin optimizasyonu (Adaptive Moment Estimation)

LSTM : Uzun kısa süreli bellek (Long Short-Term Memory)

YSA : Yapay sinir ağı

# TABLOLAR LİSTESİ

**Tablo 3.1.** *VeriSeti1'de elde edilen sonuçlar* ..... 36
**Tablo 3.2.** *VeriSeti2'de elde edilen sonuçlar* ..... 36

# ŞEKİLLER LİSTESİ

**Şekil 1.1.** *Çok katmanlı algılayıcı (MLP) mimarisinin genel yapısı*.....9
**Şekil 1.2.** *Tek boyutlu konvolüsyonel sinir ağı (1D-CNN) modelinin mimari yapısı* .....13
**Şekil 1.3.** *Uzun kısa süreli bellek (LSTM) hücresinin iç yapısı*.....16
**Şekil 1.4.** *Çift yönlü LSTM mimarisinin teorik yapısı (BiLSTM)* .....19
**Şekil 1.5.** *Kapı kontrollü tekrarlayan birim (GRU) hücresinin iç yapısı* .....21
**Şekil 2.1.** *Kompleks-değerli verilerin standart ağ yapılarında kullanılmasına olanak sağlayan yapı* .....24
**Şekil 2.2.** *Çok katmanlı algılayıcı (MLP) yapısı*.....27
**Şekil 2.3.** *Bir boyutlu evrişimsel sinir ağı (1DCNN) yapısı* .....28
**Şekil 2.4.** *Uzun kısa süreli bellek (LSTM) hücresi* .....29
**Şekil 2.5.** *Uzun kısa süreli bellek (LSTM) yapısı*.....30
**Şekil 2.6.** *Çift yönlü LSTM yapısı (BiLSTM)*.....31
**Şekil 2.7.** *GRU hücresinin iç yapısı*.....32
**Şekil 3.1.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*.....39
**Şekil 3.2.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) majiner eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*.....40
**Şekil 3.3.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile MLP modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği.* .....42
**Şekil 3.4.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar* .....43
**Şekil 3.5.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar* .....44

**Şekil 3.6.** *VeriSeti1(a) ve VeriSeti2'de(b) gerçek değerler ile 1D-CNN modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği.* ..... 46
**Şekil 3.7.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*..... 47
**Şekil 3.8.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*..... 48
**Şekil 3.9.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile LSTM modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği.* ..... 49
**Şekil 3.10.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*..... 50
**Şekil 3.11.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*..... 51
**Şekil 3.12.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile BiLSTM modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği.* ..... 53
**Şekil 3.13.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*..... 54
**Şekil 3.14.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*..... 55
**Şekil 3.15.** *VeriSeti1(a) ve VeriSeti2'de(b) gerçek değerler ile GRU modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği.* ..... 56

**Şekil 3.16.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar* ..... 57
**Şekil 3.17.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar* ..... 58
**Şekil 3.18.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile 1D-CNN + LSTM modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği.* ..... 60

# GİRİŞ

Endüstri devrimi ve modern yaşam, kömür, petrol ve doğal gaz gibi geleneksel fosil yakıtlara dayanmaktadır. Ancak, bu yakıtların yoğun kullanımı beraberinde önemli çevresel sorunları getirmektedir. Fosil yakıtların yanması sonucu açığa çıkan sera gazları, atmosferde birikerek küresel ısınmaya ve iklim değişikliğine yol açmaktadır (Chen vd., 2022; Wu vd., 2022). Bu durum, sadece çevreye zarar vermekle kalmamakta, aynı zamanda insan sağlığını da tehdit etmektedir (World Health Organization, 2023). Fosil yakıtlar yenilenemez kaynaklar olduğundan, uzun vadede enerji ihtiyacını karşılamak için sürdürülebilir bir çözüm sunmamaktadır (Y. Li vd., 2022).

Bu nedenle, son yıllarda temiz ve yenilenebilir enerji kaynaklarına olan ilgi giderek artmaktadır. Çin gibi enerji talebi yüksek olan ülkeler, enerji politikalarını temiz enerji kaynaklarına yönlendirmektedirler (Duyar vd., 2023). Bu politikaların başında, fotovoltaik ve rüzgâr enerjisi üretimini de kapsayan dağıtık enerji üretim stratejisi gelmektedir (Long vd., 2022). Dağıtık enerji üretimi, enerjinin tüketim merkezlerine yakın noktalarda üretilmesini sağlayarak iletim kayıplarını azaltmakta ve enerji verimliliğini artırmaktadır. Ayrıca, yenilenebilir enerji kaynaklarının kullanımı, enerji arz güvenliğini sağlamak ve dışa bağımlılığı azaltmak açısından da büyük önem taşımaktadır.

Yenilenebilir enerji kaynakları arasında en hızlı gelişen ve en umut vadedenlerden biri rüzgâr enerjisidir. Rüzgâr enerjisi, temiz, bol, düşük maliyetli ve çevre dostu bir enerji kaynağıdır (Y. Li vd., 2018; L. Wang vd., 2022). Küresel Rüzgâr Enerjisi Konseyi'nin (GWEC) 2025 yılına ait raporuna göre, yalnızca 2024 yılı içerisinde küresel ölçekte 117 GW düzeyinde yeni rüzgâr enerjisi kapasitesi devreye alınmış ve toplam kurulu güç 1.136 GW'a ulaşmıştır; bu da önceki yıla kıyasla yaklaşık %11,2'lik bir büyümeye karşılık gelmektedir (GWEC, 2025a). Offshore rüzgâr enerjisi tarafında ise 8 GW'lık yeni kurulum gerçekleştirilmiş ve toplam offshore kapasite 83 GW düzeyine erişmiştir

(GWEC, 2025b). Bu güçlü büyüme, rüzgâr enerjisinin olgunlaşmış bir teknoloji haline geldiğini ve enerji sektöründe giderek daha belirleyici bir rol oynadığını göstermektedir. Ancak, GWEC raporlarında da vurgulandığı üzere, 2030 yılına kadar sürdürülebilir kalkınma hedeflerine ulaşmak için yıllık en az 320 GW'lık kurulumlara ihtiyaç duyulmaktadır (GWEC, 2025a). Bu hızlı büyüme, rüzgâr enerjisinin artık olgunlaşmış bir teknoloji olduğunu ve enerji sektöründe önemli bir rol oynadığını göstermektedir. Rüzgâr enerjisinin faydaları sadece enerji üretimi ile sınırlı değildir. Rüzgâr enerjisi sektörü, aynı zamanda önemli bir istihdam kaynağıdır. Amerika Birleşik Devletleri'nde 2019 yılı itibarıyla 120.000'den fazla kişi rüzgâr enerjisi sektöründe çalışmaktadır ve bu sayının 2050 yılına kadar 500.000'e ulaşması beklenmektedir (American Wind Energy Association, 2020). Rüzgâr enerjisi projeleri genellikle kırsal alanlarda hayata geçirildiğinden, bu alanlarda yaşayan topluluklar için ekonomik kalkınma fırsatları sunmaktadır. Ayrıca, rüzgâr enerjisi, ülkelerin enerji bağımsızlığını artırmalarına ve enerji ithalatına olan bağımlılıklarını azaltmalarına yardımcı olmaktadır.

Rüzgâr enerjisi teknolojisi sürekli gelişmekte ve daha verimli hale gelmektedir. Türbin boyutlarının büyümesi, daha fazla enerji üretilmesini ve maliyetlerin düşmesini sağlamaktadır (Global Wind Energy Council, 2022; International Renewable Energy Agency, 2022). Aynı zamanda, rüzgâr enerjisi santrallerinin kurulum süreleri kısalmakta ve yatırım geri dönüşleri hızlanmaktadır. Offshore rüzgâr enerjisi, denizlerde daha güçlü ve istikrarlı rüzgârlardan yararlanarak enerji üretimini artırmakta ve kıyı alanlarının daha verimli kullanılmasını sağlamaktadır (WindEurope, 2022).

Rüzgâr enerjisinin potansiyelini tam olarak değerlendirebilmek için rüzgâr hızı ve yönünün doğru bir şekilde tahmin edilmesi büyük önem taşımaktadır. Rüzgâr hızı ve yönü tahmini, enerji üretiminin planlanması, türbinlerin kontrolü ve enerji şebekelerinin yönetimi gibi birçok alanda kritik bir rol oynamaktadır. Bu nedenle, rüzgâr tahmini konusunda yapılan çalışmalar, rüzgâr enerjisinin verimli ve güvenilir bir şekilde kullanılmasına önemli katkılar sağlamaktadır.

Rüzgâr enerjisi, temiz ve sürdürülebilir bir enerji kaynağı olarak kabul edilse de bazı dezavantajları da beraberinde getirmektedir. Rüzgâr enerjisi üretiminin en önemli dezavantajlarından biri, rüzgârın kesintili bir kaynak olmasıdır. Rüzgâr hızı, hava yoğunluğu ve türbin özellikleri gibi faktörlerdeki değişimler, enerji üretiminde büyük dalgalanmalara neden olabilir (Soman vd., 2010). Bu durum, enerji şebekelerinin

dengesini sağlamayı ve enerji arz güvenliğini korumayı zorlaştırır. Ayrıca, rüzgâr enerjisinin depolanması ve iletilmesi de önemli bir sorun teşkil etmektedir. Mevcut enerji depolama teknolojileri, rüzgâr enerjisinin aralıklı doğasına uygun çözümler sunamamakta ve maliyetli olmaktadır (Wu vd., 2022).

Rüzgâr enerjisi santrallerinin verimli bir şekilde çalışabilmesi için rüzgâr hızı ve yönünün doğru bir şekilde tahmin edilmesi gerekmektedir. Rüzgâr hızı, türbinlerin üreteceği enerji miktarını doğrudan etkilediğinden, rüzgâr hızı tahmini enerji üretiminin planlanması ve yönetimi açısından kritik öneme sahiptir (Cadenas vd., 2016). Rüzgâr hızı ve yönü tahmini, aynı zamanda türbinlerin rüzgâra göre optimize edilmiş şekilde konumlandırılması ve enerji şebekelerinin etkin bir şekilde yönetilmesi için de gereklidir.

Bu nedenle, rüzgâr hızı ve yönü tahmini, rüzgâr enerjisi sistemlerinin verimliliği ve güvenilirliği açısından büyük önem taşımaktadır. Literatürde, rüzgâr hızı ve yönü tahmini için çeşitli yöntemler kullanılmaktadır. Bu yöntemler arasında fiziksel modeller (Giebel vd., 2011), istatistiksel modeller (Nielsen vd., 2006), mekansal-zamansal modeller (Erdem & Shi, 2011) ve yapay zekâ tabanlı modeller yer almaktadır.

Literatürde, rüzgâr hızını tahmin etmek için farklı teknikler kullanılmış olup ve bu teknikler genellikle dört farklı kategoride sınıflandırılmıştır (Erdem & Shi, 2011).

İlk kategori, rüzgâr hızını tahmin etmek için arazi, engeller, basınç ve sıcaklık gibi bazı fiziksel özelliklerin kullanılmasını içermektedir (Landberg, 2001). Bu kategoride, genellikle büyük ölçekli hava tahmini yapabilmek için Sayısal Hava Tahmini (Numerical Weather Prediction - NWP) modelleri kullanılmaktadır. NWP modelleri, atmosferik olayları ve coğrafi koşulları matematiksel olarak modelleyerek rüzgâr hızı ve yönü gibi meteorolojik değişkenleri tahmin etmeyi amaçlar. Bu modeller, genellikle atmosferik fiziği ve dinamiği ile ilgili denklemleri çözmek için karmaşık algoritmalar ve sayısal yöntemler kullanır. NWP modelleri, hava durumu tahminleri, iklim modellemesi ve çevresel çalışmalar gibi birçok alanda yaygın olarak kullanılmaktadır.

NWP modellerinin avantajları arasında, geniş bir coğrafi alanı kapsayabilmeleri, uzun vadeli tahminler yapabilmeleri ve farklı meteorolojik değişkenleri aynı anda tahmin edebilmeleri yer almaktadır. Ancak, bu modellerin bazı dezavantajları da vardır. NWP modelleri, hesaplama açısından yoğun olabilir ve yüksek işlem gücü gerektirebilir. Ayrıca, bu modellerin doğruluğu, başlangıç koşullarının doğruluğuna ve modelin karmaşıklığına bağlıdır. NWP modelleri, yerel rüzgâr koşullarındaki ani değişiklikleri ve

küçük ölçekli rüzgâr olaylarını tahmin etmede zorlanabilir. Bu nedenle, NWP modelleri genellikle kısa vadeli ve yerel rüzgâr hızı tahminleri için uygun değildir.

İkinci kategori, klasik istatistiksel yaklaşımları içerir. Literatürde dikkate değer istatistiksel yaklaşımlar arasında Box-Jenkins tarafından tanıtılan otoregresif bütünleşik hareketli ortalama (ARIMA) tabanlı modeller bulunmaktadır. ARIMA modelleri, zaman serisi verilerindeki otokorelasyonları ve eğilimleri modelleyerek gelecekteki değerleri tahmin etmek için kullanılır. Bu modeller, özellikle kısa vadeli rüzgâr hızı tahminlerinde yaygın olarak kullanılmaktadır (Box vd., 1994).

ARIMA modelleri, zaman serisi verilerinin durağan hale getirilmesi ve ardından otoregresif (AR), bütünleşik (I) ve hareketli ortalama (MA) bileşenlerinin model parametrelerinin belirlenmesi adımlarını içerir. Model parametreleri, genellikle geçmiş verileri kullanarak tahmin hatasını en aza indirecek şekilde optimize edilir. ARIMA modelleri, farklı zaman aralıklarında ve farklı veri setlerinde rüzgâr hızı tahmini için kullanılmıştır.

Örneğin, araştırmacılar, rüzgâr hızını tahmin etmek için ARIMA modellerinde otokorelasyon, Gauss olmayan dağılım ve günlük durağan olmamayı bir araya getirmişlerdir (Lalarukh & Yasmin, 1997). Diğer çalışmalar ise yaklaşık Gauss olan rüzgâr hızı dağılımlarını elde etmek için karekök dönüşümü kullanmış ve rüzgâr hızı ile güç arasındaki bağlantıyı kurmuş ve geçmiş rüzgâr hızı verileri için otokorelasyonları analiz etmişlerdir (Brown vd., 1984). Başka bir çalışmada ise, ARIMA tabanlı modelleri kalıcılık tabanlı modellerle karşılaştırmışlardır (Torres vd., 2005). Kalıcılık modeli tarafından sağlanan tahminlerin daha kısa tahmin ufukları için ARIMA tabanlı modellerden daha iyi başarım sergilediği, daha uzun tahmin ufukları için ise ARIMA tabanlı modellerin kalıcılık modeline kıyasla tutarlı bir şekilde daha iyi başarım gösterdiği ortaya konulmuştur (Torres vd., 2005). Bu nedenle, hibrit tahmin sistemleri, farklı modelleme stratejilerini bir araya getirerek rüzgâr hızı tahminlerinde daha yüksek doğruluk sağlayabilmektedir (Zhou vd., 2019).

ARIMA modelleri, rüzgâr hızı tahmini için etkili bir yöntem olsa da bazı sınırlamaları da vardır. Bu modeller, doğrusal bir yapıya sahip olduklarından, rüzgâr hızındaki nonlineer değişimleri tam olarak yakalayamayabilirler. Ayrıca, ARIMA modelleri, uzun vadeli tahminlerde doğruluklarını kaybedebilirler.

Üçüncü kategoride, mekansal-zamansal modeller yer almaktadır (Yu vd., 2018). Sadece zaman serisi verilerini kullanarak tahmin yapan istatistiksel modellerin aksine, mekansal-zamansal modeller, coğrafi konum bilgisini de dikkate alarak komşu bölgelerdeki rüzgâr hızı ölçümlerine göre tahmin yaparlar. Bu modellerin temel dayanağı, komşu bölgelerdeki rüzgâr hızlarının birbiriyle ilişkili olduğu ve bu ilişkinin tahmin doğruluğunu artırabileceği fikridir.

Mekansal-zamansal modeller, rüzgâr hızının hem zamana hem de konuma bağlı olarak değiştiği gerçeğini yansıtır. Bu modeller, genellikle bir bölgedeki rüzgâr hızını tahmin etmek için komşu bölgelerdeki rüzgâr hızlarını ve diğer meteorolojik verileri kullanır. Özellikle rüzgâr enerjisi santrallerinin planlaması ve işletilmesi için önemlidir, çünkü rüzgâr enerjisi üretiminin verimliliği, rüzgârın hem hızına hem de yönüne bağlıdır.

Bu modellerde, rüzgâr hızı ve yönünü tahmin etmek için farklı matematiksel ve istatistiksel yöntemler kullanılabilir (Liu vd., 2018; Shukur & Lee, 2015). Bazı modeller, komşu bölgelerdeki rüzgâr hızları arasındaki korelasyonu modellemek için otoregresif modeller kullanırken, diğerleri, rüzgâr hızının zamansal ve mekansal değişimini modellemek için yapay sinir ağları veya destek vektör makineleri gibi makine öğrenmesi tekniklerini kullanabilir.

Mekansal-zamansal modellerin avantajları arasında, rüzgâr hızının hem zamansal hem de mekansal değişimini dikkate almaları ve komşu bölgelerdeki bilgileri kullanarak daha doğru tahminler yapabilmeleri yer almaktadır. Ancak, bu modellerin dezavantajları da vardır. Mekansal-zamansal modellerin karmaşıklığı, hesaplama maliyetlerini artırabilir ve modelin eğitimi için büyük veri setleri gerektirebilir. Ayrıca, bu modellerin doğruluğu, kullanılan verilerin kalitesine ve modelin karmaşıklığına bağlıdır.

Son olarak, dördüncü kategori ise yapay zekâ ve makine öğrenimi yöntemlerini içermektedir. Bu yöntemler, rüzgâr hızı ve yönü tahmini gibi karmaşık problemleri çözmek için bilgisayar algoritmalarını ve istatistiksel modelleri kullanır. Yapay zekâ ve makine öğrenimi yöntemleri, büyük veri setlerini analiz edebilme ve karmaşık örüntüleri öğrenebilme yetenekleri sayesinde rüzgâr enerjisi tahmininde giderek daha popüler hale gelmektedir.

Literatürde yapılan çalışmalar incelendiğinde, bazı araştırmacılar (G. Li & Shi, 2010), rüzgâr hızını tahmin etmek için üç farklı yapay sinir ağını (YSA) kendi içerisinde karşılaştırmışlar ve sinir ağı tipi ve parametrelerinin seçiminin rüzgâr hızı tahmininin

başarımını büyük ölçüde etkilediğini ortaya koymuşlardır. YSA'lar, insan beyninin bilgi işleme şeklini taklit eden matematiksel modellerdir ve rüzgâr hızı gibi karmaşık zaman serisi verilerindeki nonlineer örüntüleri öğrenebilirler. Yapılan bu çalışma, YSA'ların rüzgâr hızı tahmini için etkili bir araç olabileceğini göstermektedir.

Farklı bir çalışma olarak, diğer bilim insanları (Mabel & Fernandez, 2008), YSA tabanlı bir modeli eğitmek için girdi değişkenleri olarak rüzgâr hızı, bağıl nem ve üretim saatlerini kullanmışlar ve oldukça tatmin edici sonuçlar elde etmişlerdir. Bu çalışma, YSA modellerinin rüzgâr hızı tahmininde kullanılabilecek farklı girdi değişkenlerini ve bu değişkenlerin tahmin başarımına etkisini incelemektedir.

Literatürde benimsenen diğer yapay zekâ ve makine öğrenimi yöntemleri arasında bulanık mantık (Chang vd., 2014), destek vektör makinesi (Cadenas vd., 2016) ve bazı hibrit yöntemler (J. Wang vd., 2016) de yer almaktadır. Bulanık mantık, belirsizlik ve kesin olmayan bilgileri işleyebilen bir yapay zekâ yöntemidir ve rüzgâr hızı tahmininde kullanıldığında, rüzgâr hızındaki belirsizlikleri ve rassallığı modellemeye yardımcı olabilir. Destek vektör makineleri ise, verileri sınıflandırmak ve regresyon analizi yapmak için kullanılan güçlü bir makine öğrenmesi yöntemidir ve rüzgâr hızı tahmininde yüksek doğruluk sağlayabilir. Hibrit yöntemler ise, farklı yapay zekâ ve makine öğrenimi yöntemlerini birleştirerek daha güçlü ve esnek tahmin modelleri oluşturmayı amaçlar.

Öte yandan, rüzgâr yönü, belirli bir rüzgâr hızında en fazla gücü elde etmek ve böylece verimi artırmak için türbin kontrolünde de dikkate alınması gereken önemli bir değişkendir. Bu değişken tahmin edilerek, en fazla enerji çıkışını elde etmek için türbini rüzgâr yönü ile hizalamak mümkün olabilmektedir. Fakat literatürde rüzgâr yönünü tahmin etmeye yönelik araştırmalar çok fazla değildir.

Yapay zekâ ve makine öğrenimi yöntemleri, rüzgâr enerjisi sektöründe giderek daha fazla kullanılmaktadır (Goodfellow vd., 2016; Hu vd., 2016; Marugán vd., 2018). Bu yöntemler, rüzgâr hızı ve yönü tahmini, enerji üretimi optimizasyonu ve türbin bakımı gibi alanlarda önemli avantajlar sunmaktadır. Derin öğrenme, özellikle son yıllarda popülerlik kazanan bir makine öğrenimi yöntemidir ve rüzgâr enerjisi tahmininde başarılı sonuçlar elde edilmesini sağlamıştır.

MLP (G. Li & Shi, 2010), 1DCNN (Mabel & Fernandez, 2008) ve LSTM (Ehsan vd., 2020) gibi derin öğrenme modelleri, rüzgâr hızı ve yönü tahmini için yaygın olarak kullanılmaktadır. Bu modeller, farklı mimarilere ve öğrenme yeteneklerine sahiptir.

MLP, basit bir yapıya sahip olup, girdi verilerini işleyerek çıktı tahminleri üretir. 1DCNN, özellikle zaman serisi verilerinde etkili olan bir modeldir ve rüzgâr verilerindeki zamansal örüntüleri yakalamak için kullanılabilir. LSTM ise uzun vadeli bağımlılıkları modelleme yeteneğine sahip bir modeldir ve rüzgâr hızı ve yönündeki değişimleri tahmin etmede etkili olabilir. RNN (Zhang vd., 2020) ve GRU (J. Wang vd., 2016) modelleri de zaman serisi verilerinde sıklıkla kullanılan derin öğrenme modelleridir. RNN, tekrarlayan bir yapıya sahip olup, geçmiş bilgileri kullanarak gelecekteki değerleri tahmin edebilir. GRU ise LSTM'nin daha basit bir versiyonu olarak düşünülebilir ve daha az parametreye sahiptir. CNN (Liu vd., 2018) ise genellikle görüntü işleme alanında kullanılan bir model olsa da rüzgâr verilerindeki mekansal örüntüleri yakalamak için de kullanılabilir. Bu modellerin performansı, kullanılan veri kümesine, modelin mimarisine ve hiper parametrelere bağlı olarak değişebilir. Bu nedenle, rüzgâr hızı ve yönü tahmini için en uygun modelin seçimi, uygulamaya özgü gereksinimlere ve veri özelliklerine bağlıdır.

Son yıllarda, rüzgâr hızı ve yönü tahmininde doğruluğu artırmak amacıyla kompleks-değerli veri temsilleri ve adaptif sinyal işleme yöntemleri giderek daha fazla ilgi görmektedir. Literatürde, rüzgâr sinyalinin ayrılmaz iki bileşeni olan hız ve yönün birlikte modellenmesi gerektiği ifade edilmekte olup, bu doğrultuda yapılan çalışmalar geleneksel yöntemlere kıyasla daha bütüncül bir yaklaşım sunmaktadır. Bazı araştırmacılar tarafından geliştirilen bir modelde, rüzgâr vektörünün kompleks-değerli bir nicelik olarak temsil edilmesi önerilmiş ve bu sayede hem rüzgâr hızı hem de yönünün aynı anda tahmin edilmesine olanak tanıyan yeni bir metodoloji ortaya konulmuştur (Goh vd., 2004, 2006). Bu yaklaşım, hız ve yön bileşenlerinin bağımsız olarak değerlendirilmesi yerine, heterojen bir füzyon sürecine tabi tutulmasını sağlayarak tahmin doğruluğunu artırma potansiyeline sahiptir (Alexiadis vd., 1998).

Kompleks düzlem tabanlı bu modelleme çerçevesi, adaptif sinyal işleme yöntemleri ile entegre edildiğinde, rüzgâr tahmini süreçlerinde daha yüksek hassasiyet elde edilmesine katkıda bulunabilmektedir. Yapılan bazı araştırmalarda, kompleks-değerli analizlerin rüzgâr hızını ve yönünü eş zamanlı olarak modelleme açısından önemli avantajlar sunduğu gösterilmiştir (Mandic, Kuh, vd., 2009; Mandic, Zhang, vd., 2009). Ancak, bu yaklaşımların büyük ölçüde sonlu dürtü cevabı (Finite Impulse Response, FIR) ve nadiren de olsa sonsuz dürtü cevabı (Infinite Impulse Response, IIR) filtre yapıları ile sınırlandırıldığı görülmektedir. Doğrusal yapıya sahip olan bu filtreleme yöntemleri,

rüzgâr sinyallerinin dinamik ve doğrusal olmayan doğasını tam anlamıyla yansıtamamakta ve özellikle modelin eğitim aşaması sonrasında test aşamalarında istenilen performans düzeyine ulaşılmasını zorlaştırmaktadır (Mengüç & Acır, 2018; Smith & Tanaka, 2012).

Bu nedenle, rüzgâr tahmin modellerinde kompleks-değerli veri kullanımına yönelik daha esnek ve güçlü yöntemlerin geliştirilmesi gerektiği açıktır. Bu bağlamda, çalışmamız kompleks-değerli rüzgâr verilerini doğrudan model girişine dahil ederek, geleneksel doğrusal tahmin yaklaşımlarının sınırlamalarını aşmayı ve rüzgâr tahmin süreçlerinde doğruluk oranını artırmayı hedeflemektedir.

Bu çalışmada, kısa vadeli rüzgâr hızı ve yönü tahmini için kompleks-değerli rüzgâr verilerini giriş olarak kullanan farklı derin öğrenme modelleri değerlendirilmiştir. Geleneksel sinir ağı yapılarında kompleks-değerli verilerin doğrudan kullanımı mümkün olmadığından, bu verileri işleyebilecek özel bir yapı geliştirilmiştir. Çalışmada, rüzgârın yalnızca hız ve yön bilgileri kullanılarak tahmin edilmesi hedeflenmiş ve kompleks düzlem kullanılarak üç farklı derin öğrenme modeli karşılaştırılmıştır. Bu kapsamda, çok katmanlı algılayıcı (MLP), bir boyutlu evrişimsel sinir ağları (1DCNN) ve uzun-kısa süreli bellekler (LSTM), çift yönlü uzun kısa süreli bellek ağı (BiLSTM), kapı kontrollü tekrarlayan birim (GRU), yöntemleri kullanılarak, rüzgâr tahmini üzerindeki başarımları analiz edilmiştir. Elde edilen bulgular, kompleks-değerli veri kullanımının rüzgâr kestirim modellerine etkisini inceleyerek, gelecekteki çalışmalar için önemli bir temel oluşturmayı amaçlamaktadır.

Tezin geri kalanı şu şekilde devam etmektedir: Birinci Bölüm’de, çalışmada kullanılan materyaller ve yöntemler detaylandırılmakta olup, rüzgâr tahmininde kullanılan MLP, 1DCNN, LSTM, BiLSTM, GRU modelleri açıklanmaktadır. İkinci Bölüm’de, önerilen tahmin modelinin tasarımı ele alınarak, kısa vadeli rüzgâr hızı tahmin edicilerinin oluşturulma süreci detaylandırılmaktadır. Üçüncü Bölüm’de, gerçekleştirilen deneyler sonucunda elde edilen benzetim sonuçları sunulmakta ve modellerin performansları kapsamlı bir şekilde tartışılmaktadır. Son olarak, Dördüncü Bölüm'de yapılan çalışmanın genel sonuçları özetlenmekte, elde edilen bulgular değerlendirilerek gelecekteki çalışmalar için öneriler sunulmaktadır.

# BİRİNCİ BÖLÜM

# MATERYAL VE METOT

## 1.1. Çok Katmanlı Algılayıcı (Multilayer Perceptron - MLP)

Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP), ileri beslemeli (feedforward) ve tam bağlantılı (fully connected) bir yapay sinir ağı modelidir. Bu model, en az bir gizli katmana sahip olup, doğrusal olmayan ilişkileri öğrenme yeteneği sayesinde karmaşık veri yapılarını modelleme kapasitesine sahiptir (Haykin, 2009). Tek katmanlı yapay sinir ağlarına kıyasla, MLP'nin gizli katmanları aracılığıyla daha kompleks fonksiyonları öğrenme kabiliyeti gelişmiştir ve bu durum, özellikle çok boyutlu veri setleri üzerinde daha iyi genelleme yapmasını sağlamaktadır (Goodfellow vd., 2016).

**Şekil 1.1.** *Çok katmanlı algılayıcı (MLP) mimarisinin genel yapısı*

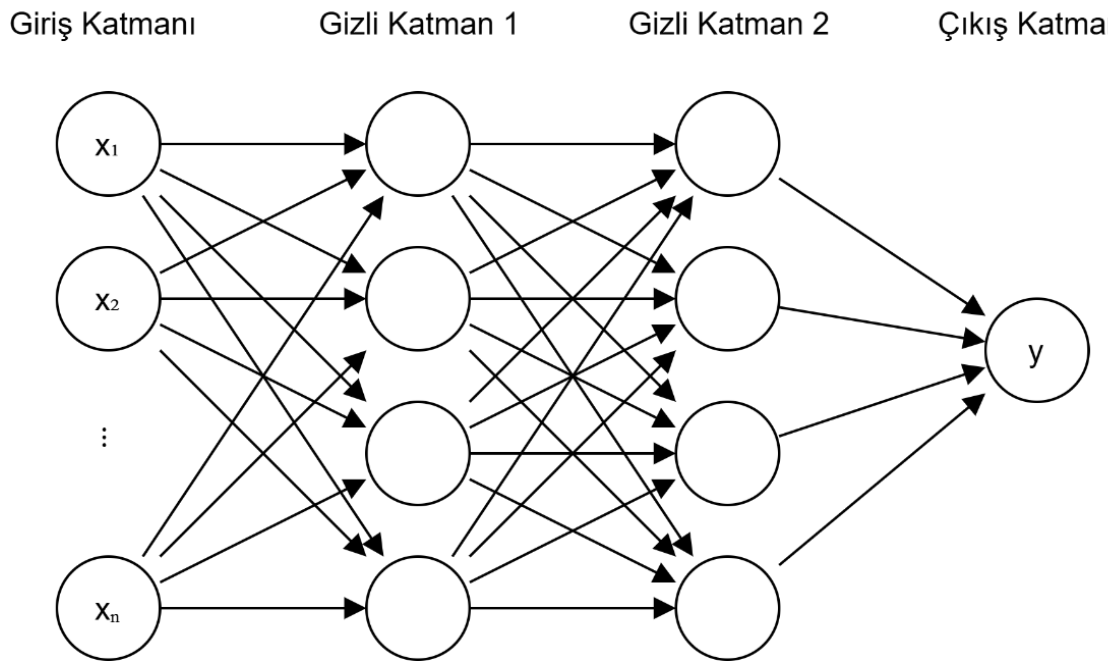


MLP modeli, giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere üç temel

bileşenden oluşmaktadır. Modelin işleyişi, giriş katmanından alınan bilgilerin ağırlıklbağlantılar aracılığıyla gizli katmanlara iletilmesi, burada aktivasyon fonksiyonları kullanılarak doğrusal olmayan dönüşümler uygulanması ve nihai olarak çıkış katmanında tahminin üretilmesi sürecini kapsamaktadır. MLP'nin en belirgin özelliklerinden biri, her nöronun bir önceki katmandaki tüm nöronlarla bağlantılı olmasıdır. Bu yapı, modelin yüksek parametre sayısına sahip olmasına yol açarken aynı zamanda büyük veri setleri üzerinde öğrenme sürecini daha güçlü hale getirmektedir (LeCun vd., 2015).

Giriş katmanı, modelin dış dünyadan aldığı bilgileri temsil eden bir katmandır. Her bir giriş değişkeni, modelin öğrenme sürecinde kullanılmak üzere ayrı bir nöron olarak tanımlanır. Matematiksel olarak, giriş katmanındaki veriler bir vektör olarak gösterilebilir:

$$X = [x_1, x_2, \ldots, x_n] \tag{1.1}$$

Burada $n$, giriş değişkenlerinin sayısını ifade etmektedir. Giriş katmanından gelen veriler, ağırlıklarla çarpılarak bir sonraki katmana iletilir. MLP'nin temel öğrenme bileşeni olan gizli katmanlar, ağırlıklarla çarpılmış giriş verilerini aktivasyon fonksiyonları aracılığıyla doğrusal olmayan dönüşümlere tabi tutarak, modelin öğrenme sürecini gerçekleştirir. Her bir gizli katmandaki nöronun çıktısı matematiksel olarak şu şekilde tanımlanır (Hornik, 1991):

$$h_j^l = f\left(\sum_{i=1}^{n^{(l-1)}} w_{ji}^{(l)} h_i^{(l-1)} + b_j^{(l)}\right) \tag{1.2}$$

Burada $h_j^{(l)}$, $l$ katmanındaki $j$ nöronunun aktivasyon fonksiyonundan geçen çıktısını ifade eder. $w_{ji}^{(l)}$, $l$ katmanındaki $j$ nöronu ile $l-1$ katmanındaki $i$ nöronu arasındaki ağırlığı temsil eder. Benzer şekilde, $h_i^{(l-1)}$, önceki katmandan gelen girişi, $b_j^{(l)}$ bias terimini ve $f(.)$ ktivasyon fonksiyonunu göstermektedir

Çıkış katmanı, MLP'nin nihai tahmin sonucunu ürettiği katmandır ve kullanılan aktivasyon fonksiyonu, problemin türüne göre değişiklik göstermektedir. Sınıflandırma problemlerinde softmax aktivasyon fonksiyonu kullanılarak çıktı değerleri olasılıklara dönüştürülür:

$$y_k = \frac{e^{z_k}}{\sum_{j=1}^{K} e^{z_j}} \tag{1.3}$$

Öte yandan, regresyon problemlerinde genellikle doğrusal aktivasyon fonksiyonu kullanılmaktadır ve bu durumda çıktı şu şekilde hesaplanır:

$$y = \sum_{j=1}^{m} w_j h_j + b \tag{1.4}$$

MLP modellerinde aktivasyon fonksiyonları, modelin doğrusal olmayan ilişkileri öğrenmesini sağlayan kritik bileşenlerdir. Bir yapay sinir ağı modelinde, giriş değerleri ağırlıklandırıldıktan ve toplandıktan sonra aktivasyon fonksiyonları ile doğrusal olmayan bir dönüşüme uğratılarak sonraki katmana aktarılır. En yaygın kullanılan aktivasyon fonksiyonlarından biri olan sigmoid fonksiyonu, verileri 0 ile 1 arasında bir aralığa sıkıştırarak özellikle olasılık tabanlı sınıflandırmalarda avantaj sağlamaktadır:

$$f(z) = \frac{1}{(1 + e^{-z})} \tag{1.5}$$

Buna ek olarak, tanh fonksiyonu da yaygın olarak kullanılmaktadır ve çıktıları -1 ile 1 arasında olacak şekilde normalleştirmektedir:

$$f(z) = \frac{(e^{z} - e^{-z})}{(e^{z} + e^{-z})} \tag{1.6}$$

En sık tercih edilen aktivasyon fonksiyonlarından biri de ReLU (Rectified Linear Unit) fonksiyonudur ve negatif girdileri sıfıra çevirerek modelin öğrenme sürecini hızlandırmaktadır:

$$f(z) = \max(0, z) \tag{1.7}$$

MLP modellerinin eğitimi, hata geri yayılımı (backpropagation) ve gradyan inişi (gradient descent) algoritmalarına dayanmaktadır. Modelin öğrenme sürecinde hata fonksiyonunun minimize edilmesi için parametre güncelleme işlemi gerçekleştirilmektedir. Genel olarak kullanılan hata fonksiyonu, çapraz entropi (cross-entropy) fonksiyonudur ve şu şekilde ifade edilmektedir:

$$E = -\sum_{k=1}^{K} d_k \log(y_k) \tag{1.8}$$

Bu fonksiyon, modelin tahmin ettiği olasılıklar ile gerçek değerler arasındaki farkı hesaplayarak modelin hatasını ölçmektedir. Modelin ağırlıkları, gradyan inişi algoritması kullanılarak güncellenmektedir:

$$w^{(t+1)} = w^{(t)} - \eta \left(\frac{\partial E}{\partial w}\right) \tag{1.9}$$

Burada $\eta$, öğrenme oranını temsil etmekte olup, modelin ne kadar hızlı güncelleneceğini belirlemektedir (Ruder, 2016). Modelin eğitimi sırasında öğrenme oranı, epoch sayısı ve batch büyüklüğü gibi hiperparametreler, modelin başarımını önemli ölçüde etkilemektedir.

### 1.2. Tek Boyutlu Konvolüsyonel Sinir Ağı (1D-CNN)

Tek boyutlu konvolüsyonel sinir ağları (1D-CNN), ardışık veri yapıları üzerinde etkin şekilde çalışan, özellikle zaman serisi analizi, biyomedikal sinyal işleme ve doğal dil işleme (NLP) gibi alanlarda yaygın olarak kullanılan derin öğrenme modelleridir (LeCun vd., 1998). Geleneksel makine öğrenme yöntemlerinden farklı olarak, 1D-CNN'ler manuel özellik mühendisliği gereksinimini en aza indirerek, girdi verisinden doğrudan anlamlı özellikler çıkarabilir. Bu süreç, özellikle uzun vadeli bağımlılıkların öğrenilmesini gerektiren problemlerde modelin daha etkili çalışmasını sağlar (He vd., 2015).

Bu model, konvolüsyon işlemleri kullanarak ardışık verilerde paternleri öğrenir ve özellikleri hiyerarşik olarak çıkarır. Geleneksel tam bağlantılı ağlar (MLP) tüm girişleri aynı anda işlerken, 1D-CNN yalnızca belirli bir pencere boyutundaki (kernel) verileri işler. Bu yapı, özellikle sıralı veri analizinde modelin doğrudan zaman içindeki bağıntıları öğrenmesine olanak tanır (Schmidhuber, 2015). MLP ile kıyaslandığında, 1D-CNN daha az parametre kullanarak hem modelin eğitilme sürecini hızlandırmakta hem de aşırı öğrenmeyi (overfitting) azaltarak genelleme yeteneğini artırmaktadır (Nair & Hinton, 2010).

**Şekil 1.2.** *Tek boyutlu konvolüsyonel sinir ağı (1D-CNN) modelinin mimari yapısı*

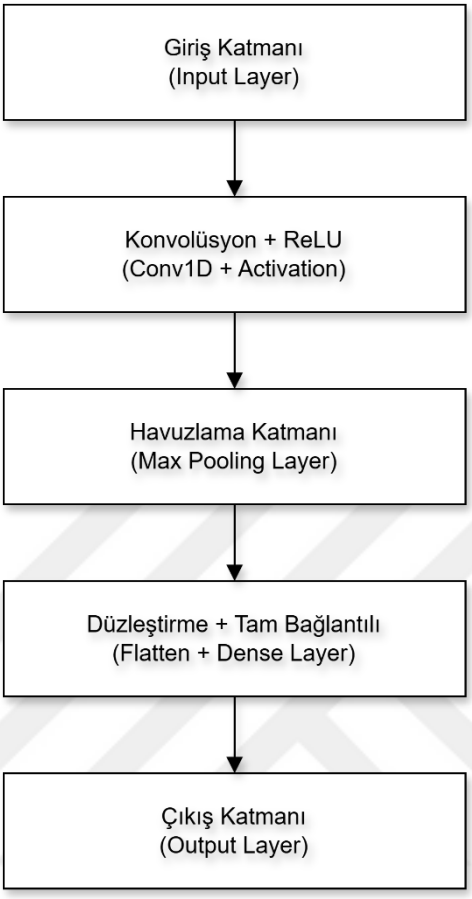


Bir 1D-CNN modeli, giriş katmanı, konvolüsyon (evrişim) katmanları, aktivasyon fonksiyonları, havuza alma (pooling) katmanları, tam bağlantılı (fully connected) katmanlar ve çıkış katmanından oluşmaktadır. Modelin işleyişi giriş verisinin doğrudan tam bağlantılı bir katmana iletilmesi yerine, sıralı olarak bu katmanlardan geçirilerek özelliklerin daha üst düzey bir temsile dönüştürülmesiyle sağlanır. Giriş katmanı, modelin doğrudan hesaplama yapmadığı ancak veriyi belirlenen formatta alıp ölçeklendirme ve normalizasyon işlemleriyle eğitime uygun hale getirdiği bölümdür. Matematiksel olarak, giriş verisi bir vektör olarak tanımlanabilir:

$$X = [x_1, x_2, \ldots, x_n] \tag{1.10}$$

Burada $n$, giriş verisinin uzunluğunu temsil etmektedir. Modelin en temel bileşeni olan konvolüsyon katmanı, giriş verisi üzerinde kayan filtreler kullanarak ardışık bağıntıları öğrenir. Bu işlem sırasında belirli bir pencere boyutundaki (kernel) giriş değerleri ile filtre ağırlıkları çarpılır ve bias terimi eklenerek aktivasyon fonksiyonuna aktarılır. Konvolüsyon işlemi şu şekilde matematiksel olarak ifade edilir:

$$y_j^l = f\left(\sum_{i=1}^{k} w_i^l x_{j+i}^{l-1} + b^l\right) \quad (1.11)$$

Burada: $y_j^l$, $l$. katmandaki $j$. nöronun konvolüsyon sonucu, $w_i^l$, $l$. katmandaki filtre ağırlıkları, $x_{j+i}^{l-1}$, önceki katmandan gelen giriş verisi, $b^l$, bias terimi, $f(.)$, aktivasyon fonksiyonu, $k$, filtrenin uzunluğu (kernel size) olarak ifade edilir.

Bu işlem sırasında, model giriş dizisini belirli bir pencere boyutuna bölerek her bir segmentin özelliklerini öğrenir. Konvolüsyon sonucunda elde edilen özellik haritaları, sıralı veri içindeki anlamlı paternleri belirlemek için kullanılmaktadır (Kingma & Ba, 2015). CNN'nin geleneksel MLP modellerinden temel farkı, her bir nöronun tüm girişleri doğrudan işlemesi yerine, yalnızca belirli bir pencere boyutundaki verilere odaklanmasıdır.

Konvolüsyon işleminden sonra aktivasyon fonksiyonları kullanılarak öğrenilen özellikler doğrusal olmayan dönüşümlere tabi tutulur. Modelin eğitimi sürecinde en yaygın olarak kullanılan aktivasyon fonksiyonu ReLU (Rectified Linear Unit) olup, negatif değerleri sıfıra eşitleyerek modelin gradyan kaybolması sorununu azaltmaktadır:

$$f(z) = \max(0, z) \quad (1.12)$$

Alternatif olarak, sigmoid ve tanh fonksiyonları da kullanılmaktadır. Sigmoid fonksiyonu, çıktı değerlerini 0 ile 1 arasında sıkıştırarak olasılık bazlı işlemler için avantaj sağlarken, tanh fonksiyonu -1 ile 1 arasında değerler üretir ve sıfır merkezli dağılımlar için daha uygundur (Bishop, 2006).

Konvolüsyon katmanlarından geçen özellik haritaları, havuza alma (pooling) işlemiyle daha kompakt hale getirilir. Havuza alma işlemi, özellikle modelin hesaplama maliyetini azaltmak ve aşırı öğrenmeyi engellemek amacıyla uygulanmaktadır. Bu işlem sırasında belirlenen bir pencere boyutu içinde en yüksek değere sahip eleman seçilerek verinin boyutu küçültülür ve en belirgin özelliklerin korunması sağlanır. Maksimum havuza alma (max-pooling) işlemi aşağıdaki gibi ifade edilir:

$$y_j = \max\left(x_{j:j+k}\right) \quad (1.13)$$

Bu işlem modelin, belirli bir zaman dilimindeki en baskın özellikleri kaybetmeden temsil etmesine olanak tanır. Ortalama havuza alma (average pooling) yöntemi ise, pencere içerisindeki tüm değerlerin ortalamasını alarak daha yumuşak bir özellik haritası üretmektedir (Ruder, 2016).

Modelin son aşamalarında, konvolüsyon ve havuza alma işlemlerinden elde edilen özellikler tam bağlantılı (fully connected) katmana aktarılır. Bu katmanda, daha önce öğrenilmiş özellikler bir sınıflandırıcıya veya regresyon modeline iletilir. Tam bağlantılı katmanda her nöron, tüm giriş verileriyle ilişkilendirilerek ağırlıklı bir toplam oluşturur ve aktivasyon fonksiyonuna iletilir. Matematiksel olarak, tam bağlantılı katmandaki her bir nöronun çıktısı şu şekilde hesaplanır:

$$z_j = \sum_{i=1}^{n} w_{ji} a_i + b_j \tag{1.14a}$$

$$a_j = f(z_j) \tag{1.14b}$$

Bu süreç, modelin öğrendiği paternleri kullanarak çıktıyı üretmesini sağlamaktadır. Son katman, problem türüne bağlı olarak farklı aktivasyon fonksiyonları ile donatılabilir; örneğin, sınıflandırma görevlerinde softmax fonksiyonu, regresyon problemlerinde ise doğrusal aktivasyon fonksiyonu kullanılmaktadır (Krizhevsky vd., 2012).

Modelin eğitimi sırasında, hata fonksiyonunun minimize edilmesi ve parametrelerin optimize edilmesi için geri yayılım algoritması (backpropagation) ve gradyan inişi (gradient descent) kullanılır. Modelin ağırlıkları ve bias terimleri, her iterasyonda güncellenerek en uygun parametre değerleri bulunur. Hata fonksiyonu aşağıdaki gibi tanımlanabilir:

$$E = -\sum_{k=1}^{K} d_k \log(y_k) \tag{1.15}$$

Ağırlık güncelleme işlemi ise gradyan inişi algoritmasıyla gerçekleştirilir:

$$w^{t+1} = w^t - \eta \left(\frac{\partial E}{\partial w}\right) \tag{1.16}$$

Burada $\eta$, öğrenme oranını temsil etmekte olup modelin ne kadar hızlı güncelleneceğini belirlemektedir (Bengio, 2009). Bu süreç, modelin öğrenme sürecini hızlandırırken, optimum ağırlık değerlerine ulaşmasını sağlamaktadır.

### 1.3. Uzun Kısa Süreli Bellek Ağı (Long Short-Term Memory - LSTM)

Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ağları, zamansal bağıntıların öğrenilmesini sağlayan, geri beslemeli (recurrent) bir yapay sinir ağı modelidir. Geleneksel geri yayılımlı sinir ağları (RNN), uzun vadeli bağıntıları öğrenmekte yetersiz kalabilirken, LSTM özel olarak tasarlanmış bellek hücreleri ve kapı mekanizmaları sayesinde geçmiş bilgileri kaybetmeden saklayarak öğrenme sürecini daha verimli hale getirmektedir (Hochreiter & Schmidhuber, 1997). Bu model, özellikle zaman serisi tahmini, biyomedikal sinyal işleme ve doğal dil işleme (NLP) gibi sıralı veri gerektiren alanlarda yaygın olarak kullanılmaktadır (Graves, 2012).

LSTM, geleneksel RNN'lerde sıkça karşılaşılan gradyan kaybolması (vanishing gradient) problemini çözüme kavuşturmak için geliştirilmiştir. Standart RNN yapılarında, modelin zaman içinde öğrendiği bilgiler genellikle uzak geçmişten gelen bilgileri kaybetmesine neden olabilir. LSTM, unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate) gibi mekanizmalar aracılığıyla hangi bilgilerin korunacağını, hangi bilgilerin güncelleneceğini ve hangi bilgilerin çıkışa iletileceğini belirler (Bengio vd., 1994).

**Şekil 1.3.** *Uzun kısa süreli bellek (LSTM) hücresinin iç yapısı*

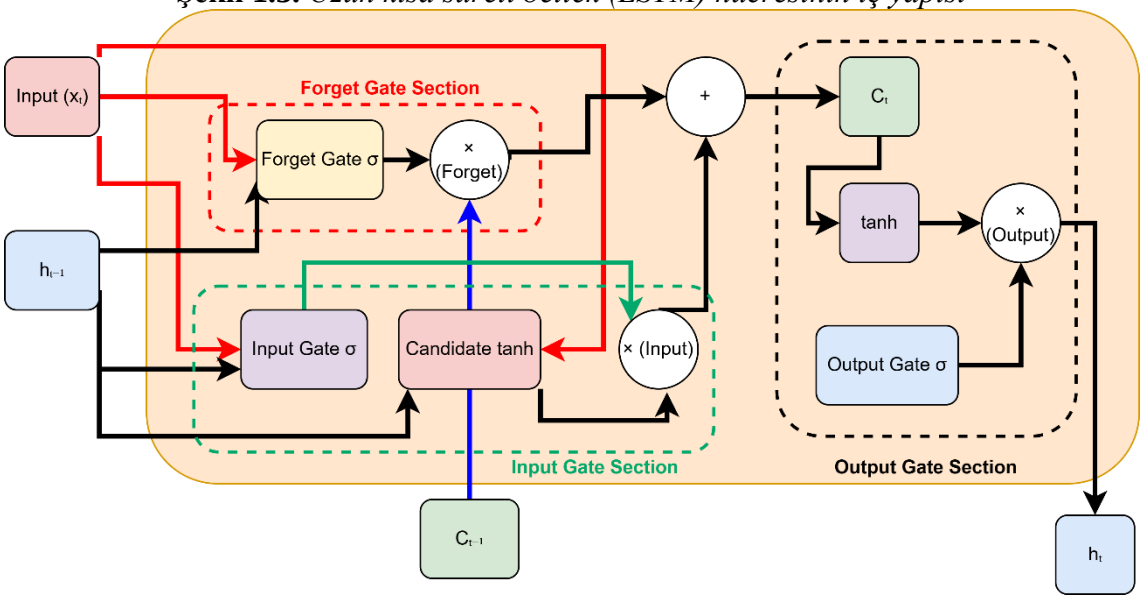

LSTM modeli, giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere üç ana bölümden oluşur. Giriş katmanı, modelin aldığı verileri işler ve gizli katmana iletir. Gizli katmanlar, sıralı bilgileri saklayarak uzun vadeli bağımlılıkları öğrenir. Çıkış katmanı ise, modelin nihai tahminini oluşturan bölümdür. Giriş katmanındaki veriler, modelin öğrenme sürecinde kullanılmak üzere bir vektör biçiminde ifade edilir:

$$X = [x_1, x_2, \ldots, x_n] \tag{1.17}$$

Burada $n$, giriş zaman adımlarının sayısını ifade etmektedir. Her zaman adımında alınan giriş verileri, LSTM hücrelerine gönderilerek işlenir ve belirli kapı mekanizmalarından geçirilir.

LSTM modelinin en önemli bileşeni olan kapı mekanizmaları, hangi bilgilerin unutulacağını, saklanacağını ve çıkış olarak verileceğini belirleyerek modelin uzun vadeli bağımlılıkları öğrenmesine olanak tanır. İlk adımda unutma kapısı devreye girerek, hangi bilgilerin saklanması gerektiğini belirler. Bu işlem, önceki hücre durumlarının belirli bir kısmını sıfıra yakın değerlere getirerek modelin gereksiz bilgileri silmesini sağlar. Matematiksel olarak, unutma kapısının çıktısı şu şekilde hesaplanır:

$$f_t = \sigma\left(W_f * [h_{t-1}, x_t] + b_f\right) \tag{1.18}$$

Burada $f_t$ , unutma kapısının çıktısını temsil eder. $W_f$ , unutma kapısının ağırlıklarıdır, $h_{t-1}$, önceki gizli durumu ifade ederken, $x_t$ mevcut giriş verisini belirtmektedir. $b_f$ bias terimidir ve $\sigma(.)$ sigmoid aktivasyon fonksiyonudur. Sigmoid fonksiyonu sayesinde, değerler 0 ile 1 arasında ölçeklendirilerek, hangi bilginin korunacağı belirlenir.

Unutma kapısından sonra, giriş kapısı devreye girerek modelin hangi bilgileri öğreneceğini belirler. Yeni bir bilgi öğrenileceğinde, giriş kapısı aktif hale gelir ve modelin bellek hücresini günceller. Bu işlem, modelin mevcut durumu nasıl güncelleyeceğini belirleyen aday bir hücre durumu oluşturarak gerçekleştirilir. Giriş kapısının çıktısı aşağıdaki gibi hesaplanır:

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \tag{1.19}$$

$$\widetilde{C_t} = \tanh(W_C * [h_{t-1}, x_t] + b_C) \tag{1.20a}$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \widetilde{C}_t \quad (1.20b)$$

Çıkış kapısı, LSTM'nin hangi bilgiyi çıktıya dönüştüreceğini belirleyen mekanizmadır. Bu işlem, güncellenen hücre durumundan anlamlı bilgiler seçerek gizli duruma aktarmak suretiyle gerçekleştirilir. Çıkış kapısının temel amacı, modelin öğrendiği bilgilerin hangi kısmının çıktı olarak aktarılacağını belirlemektir (Greff vd., 2017). Çıkış kapısının denklemleri aşağıdaki gibi hesaplanır:

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (1.21a)$$

$$h_t = o_t \odot \tanh(C_t) \quad (1.21b)$$

İlk denklem, çıkış kapısının $(o_t)$ hesaplamak için kullanılır. Bu işlem, önceki zaman adımındaki gizli durum $(h_{t-1})$ ve mevcut giriş verisi $(x_t)$ üzerine bir ağırlık matrisi $(W_o)$ uygulanarak gerçekleştirilir. Bu ağırlıklı toplam, bir bias terimi $(b_o)$ eklenerek daha esnek hale getirilir ve sonucunda sigmoid aktivasyon fonksiyonuna$(\sigma)$tabi tutulur. Sigmoid fonksiyonunun burada kullanılması, çıkış kapısının değerlerini 0 ile 1 arasında ölçeklendirerek, hangi bilgilerin çıktı olarak verileceğini belirlemesini sağlar (Goodfellow vd., 2016).

İkinci denklem, gizli durumun $(h_t)$ nasıl hesaplandığını gösterir. Burada, çıkış kapısının çıktısı $(o_t)$ ile güncellenmiş hücre durumu $(C_t)$ arasında element bazında çarpma $(\odot)$ işlemi gerçekleştirilir. Hücre durumuna tanh aktivasyon fonksiyonu uygulanarak -1 ile 1 arasında ölçeklendirilir ve çıkış kapısının çıktısı ile birleşerek yeni gizli $(h_t)$ elde edilir.

### 1.4. Çift Yönlü Uzun Kısa Süreli Bellek Ağı (Bidirectional Long Short-Term Memory - BiLSTM)

Çift Yönlü Uzun Kısa Süreli Bellek Ağı (Bidirectional Long Short-Term Memory - BiLSTM), geleneksel LSTM modelinin geliştirilmiş bir versiyonu olup, sıralı veri işlemede uzun vadeli bağımlılıkları öğrenme kapasitesini artıran bir sinir ağı modelidir. LSTM modelleri zaman serisi tahmini, konuşma tanıma ve doğal dil işleme gibi alanlarda yaygın olarak kullanılmaktadır (Graves & Schmidhuber, 2005). Ancak, standart LSTM modelleri yalnızca geçmiş verileri kullanarak tahmin yapmaktadır. Bu, gelecekten gelen verinin dikkate alınmaması nedeniyle bağlamsal anlamda eksiklikler oluşturabilir.

BiLSTM bu eksikliği gidermek için geliştirilmiş olup, verileri hem ileri hem de geri yönde işleyerek daha kapsamlı bir öğrenme sağlar (Graves, 2012).

BiLSTM modeli, giriş katmanı, çift yönlü gizli katmanlar ve çıkış katmanı olmak üzere üç temel bileşenden oluşmaktadır. Giriş katmanı, modelin aldığı sıralı verileri ileri ve geri yönlü iki farklı LSTM ağına iletir. Çift yönlü gizli katmanlar, sıralı bilgileri hem ileri hem de geri yönde işleyerek daha kapsamlı bir öğrenme gerçekleştirir. Çıkış katmanı, ileri ve geri yönlü LSTM hücrelerinden elde edilen çıktıları birleştirerek nihai tahmin sonucunu üretir. Bu yapı sayesinde, model yalnızca geçmiş veriye bağımlı olmadan, geleceğe yönelik bilgileri de göz önünde bulundurarak daha doğru tahminler yapabilir (Bengio vd., 1994).

**Şekil 1.4.** *Çift yönlü LSTM mimarisinin teorik yapısı (BiLSTM)*

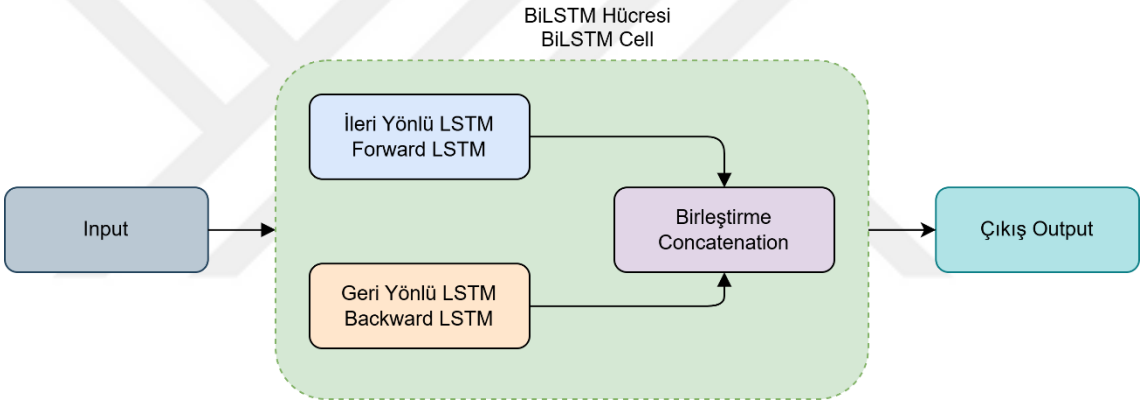


Bu model, standart LSTM'nin çözmeye çalıştığı uzun vadeli bağımlılıkları öğrenme problemini daha ileri taşıyarak iki yönlü veri akışı sağlamaktadır. LSTM, geri yayılım mekanizmasıyla uzun vadeli bağımlılıkları öğrenmeye çalışırken, ileriye dönük bilgileri kullanamaz. Bu nedenle, BiLSTM, her bir zaman adımında veriyi hem geçmiş hem de gelecekteki bilgilere dayanarak işler, böylece modelin bağlamsal bütünlüğü daha iyi kavramasını sağlar (Greff vd., 2017).

Bu modelde, giriş dizisi şu şekilde tanımlanır:

$$X = [x_1, x_2, \ldots, x_n] \tag{1.22}$$

Burada $n$, giriş zaman adımlarının sayısını ifade etmektedir. Her zaman adımında alınan giriş verileri hem ileri hem de geri yönlü LSTM hücrelerine gönderilerek işlenir (Goodfellow vd., 2016). Model, her zaman adımında iki farklı gizli durum ($h_t^{\rightarrow}$ ve $h_t^{\leftarrow}$) üretir. Biri ileri yönde, diğeri geri yönde öğrenilen bilgileri temsil eder. Bu iki gizli

durum, çıkış katmanında birleştirilerek son tahmin ($y_t$) oluşturulur (Hochreiter & Schmidhuber, 1997).

BiLSTM modelinde, kapı mekanizmaları sayesinde modelin hangi bilgileri saklayıp hangi bilgileri unutacağı belirlenir. LSTM gibi, BiLSTM de unutma kapısı, giriş kapısı, aday hücre durumu ve çıkış kapısı olmak üzere dört temel bileşenden oluşur. Ancak farkı, aynı işlemleri hem ileri hem de geri yönde gerçekleştirmesidir (Schmidhuber, 2015).

İleri yönlü LSTM'nin hesaplamaları aşağıdaki gibi gerçekleştirilir:

$$f_t^{\rightarrow} = \sigma\left(W_f^{\rightarrow} * [h_{t-1}^{\rightarrow}, x_t] + b_f^{\rightarrow}\right) \quad (1.23)$$

Bu denklemde $f_t^{\rightarrow}$, unutma kapısının çıktısını ifade eder**.** Unutma kapısı, önceki hücre durumu bilgilerinin ne kadarının korunacağını belirler**.** $W_f^{\rightarrow}$, unutma kapısının ağırlık matrisini, $h_{t-1}^{\rightarrow}$ önceki zaman adımındaki gizli durumu ve $x_t$ mevcut giriş verisini temsil etmektedir. $b_f^{\rightarrow}$ bias terimi olup, modele esneklik kazandırmaktadır (Kingma & Ba, 2015).

Giriş kapısı, yeni gelen bilgilerin hücre durumuna dahil edilip edilmeyeceğini belirler. Bu işlem aşağıdaki denklemlerle ifade edilir:

$$i_t^{\rightarrow} = \sigma(W_i^{\rightarrow} * [h_{t-1}^{\rightarrow}, x_t] + b_i^{\rightarrow}) \quad (1.24)$$

$$\tilde{C}_t^{\rightarrow} = \tanh(W_C^{\rightarrow} * [h_{t-1}^{\rightarrow}, x_t] + b_C^{\rightarrow}) \quad (1.25a)$$

$$C_t^{\rightarrow} = f_t^{\rightarrow} \odot C_{t-1}^{\rightarrow} + i_t^{\rightarrow} \odot \tilde{C}_t^{\rightarrow} \quad (1.26b)$$

Bu denklemler, modelin giriş kapısının nasıl çalıştığını ve hücre durumunun nasıl güncellendiğini göstermektedir. Giriş kapısı, yeni bilgilerin hücre durumuna eklenmesini belirler. Aday hücre durumu, giriş kapısı ve mevcut girişin işlenmesiyle oluşturulur. Son hücre durumu ise, önceki hücre durumunun unutma kapısı ile korunmuş hali ve yeni bilginin giriş kapısı ile eklenmiş halinden oluşur.

$$y_t = W_y * [h_t^{\rightarrow}, h_t^{\leftarrow}] + b_y \quad (1.27)$$

Bu işlem, hem geçmiş hem de gelecekteki bilgilere dayalı olarak modelin daha doğru tahminler yapmasına olanak tanımaktadır (Greff vd., 2017).

### 1.5. Kapı Kontrollü Tekrarlayan Birim (Gated Recurrent Unit - GRU)

Kapı kontrollü tekrarlayan birim (Gated Recurrent Unit - GRU), LSTM modelinin daha sade ve hesaplama açısından daha verimli bir versiyonu olarak geliştirilmiştir. LSTM modelleri, uzun vadeli bağımlılıkları öğrenme kapasitesine sahip olmasına rağmen, daha fazla parametre içermesi ve hesaplama maliyetinin yüksek olması nedeniyle bazı uygulamalarda kullanımı sınırlıdır (Cho vd., 2014). GRU, LSTM ile benzer bir yapıya sahip olmasına rağmen, modelin hem bellek hücre durumunu hem de gizli durumu tek bir bileşende birleştirerek daha verimli bir öğrenme süreci sunmaktadır (Hochreiter & Schmidhuber, 1997).

GRU modelinde, bilgi akışını düzenleyen iki temel kapı mekanizması bulunmaktadır: güncelleme kapısı ve sıfırlama kapısı. LSTM'nin aksine, GRU'da unutma kapısı bulunmaz. Bunun yerine, güncelleme kapısı modelin önceki zaman adımındaki gizli durumu ne kadar koruyacağını, sıfırlama kapısı ise önceki gizli durumun ne kadarını unutacağını belirler (Bengio vd., 1994). Bu mekanizma sayesinde, GRU modeli uzun vadeli bağımlılıkları öğrenme kapasitesini korurken, hesaplama yükünü ve parametre sayısını azaltmaktadır.

**Şekil 1.5.** *Kapı kontrollü tekrarlayan birim (GRU) hücresinin iç yapısı*

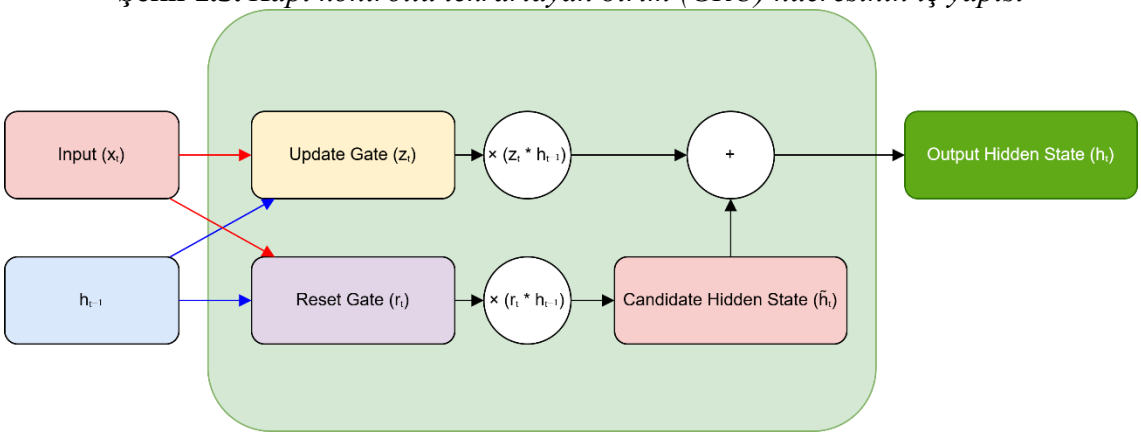


GRU modelinin giriş dizisi şu şekilde tanımlanır:

$$X = [x_1, x_2, \ldots, x_n] \tag{1.28}$$

Burada $n$, giriş zaman adımlarının sayısını ifade etmektedir. Her zaman adımında alınan giriş verileri, modelin kapı mekanizmaları üzerinden geçerek gizli durumun güncellenmesini sağlar (Goodfellow vd., 2016). GRU modelinde, her bir zaman adımı için güncelleme ve sıfırlama kapıları ayrı ayrı hesaplanmaktadır.

Güncelleme kapısı, modelin önceki zaman adımındaki gizli durumu ne kadar koruyacağını belirleyen mekanizmadır ve şu şekilde hesaplanır:

$$z_t = \sigma(W_z * [h_{t-1}, x_t] + b_z) \tag{1.29}$$

Bu denklemde $z_t$, güncelleme kapısının çıktısını ifade eder. Bu kapının ürettiği değer 0 ile 1 arasında olup, modelin mevcut gizli durumu ne kadar koruyacağını belirler. $W_z$ ağırlık matrisi ile önceki gizli durum $h_{t-1}$ ve giriş verisi $x_t$ işlenerek, modelin önceki bilgileri ne kadar saklayacağına karar verilmiş olur. Sigmoid aktivasyon fonksiyonu $\sigma(.)$ kullanıldığı için çıktı, 0 ile 1 arasında bir değer alır; eğer değer 1'e yakınsa önceki gizli durum korunur, 0'a yakınsa güncellenir (Kingma & Ba, 2015).

GRU modelinde unutma kapısı bulunmadığı için, sıfırlama kapısı modelin hangi bilgileri unutacağını belirler. Sıfırlama kapısının hesaplanması şu şekilde gerçekleştirilir:

$$r_t = \sigma(W_r * [h_{t-1}, x_t] + b_r) \tag{1.30}$$

Burada $r_t$, sıfırlama kapısının çıktısını ifade eder. Bu kapı, modelin önceki gizli durumunun ne kadarını unutacağını belirler**.** Sıfırlama kapısı, modelin uzun vadeli bağımlılıklardan ne kadar etkileneceğini ayarlamak için kullanılmaktadır. $W_r$ ağırlık matrisi ile önceki gizli durum $h_{t-1}$ ve giriş verisi $x_t$ işlenerek modelin sıfırlama kararı alınır. Eğer bu kapının çıktısı 0'a yakınsa, önceki zaman adımındaki bilgiler büyük ölçüde unutulur; 1'e yakınsa korunur (Chung vd., 2014)**.**

Sıfırlama kapısından geçen bilgi ile giriş verisi birleştirilerek, modelin mevcut zaman adımı için oluşturacağı aday gizli durum hesaplanır:

$$\tilde{h}_t = \tanh(W_h * [r_t \odot h_{t-1}, x_t] + b_h) \tag{1.31}$$

Bu denklem, yeni aday gizli durumu $\tilde{h}_t$ hesaplamak için kullanılır. Sıfırlama kapısı, önceki gizli durumun hangi kısımlarının mevcut girişle birleşerek yeni aday durumu oluşturacağını belirler**.** Bu işlem, modelin uzun vadeli bağımlılıklar ile kısa vadeli girdiler arasında bir denge kurmasına yardımcı olur (Bahdanau vd., 2014). $W_h$ ağırlık matrisi, giriş bilgisi $x_t$ ve sıfırlama kapısının filtrelediği önceki gizli durum $r_t \odot h_{t-1}$ birlikte kullanılarak $\tilde{h}_t$ hesaplanır. Bu işlem sonucunda, önceki zaman adımının tamamı kullanılabileceği gibi, bazı kısımları sıfırlama kapısı tarafından devre dışı bırakılabilir**.**

Son olarak, modelin nihai gizli durumu güncelleme kapısı ve aday gizli durum birleştirilerek hesaplanır:

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (1.32)$$

Bu denklem, modelin son olarak hangi bilgileri koruyacağını ve hangi bilgileri güncelleyeceğini belirler. Güncelleme kapısı tarafından belirlenen ağırlıklarla önceki gizli durum korunurken, aynı zamanda yeni aday gizli durumu belirli bir oranda eklenir (Vaswani vd., 2017). Eğer güncelleme kapısı tamamen açık (1) ise, model mevcut aday durumu tamamen kullanır; güncelleme kapısı kapalı (0) ise, model önceki durumu korur. Bu mekanizma sayesinde, model veri içindeki uzun vadeli bağımlılıkları öğrenebilir ve optimize edilebilir.

Bu işlemler sonucunda, GRU modeli LSTM'nin sunduğu uzun vadeli bağımlılıkları öğrenme kapasitesini koruyarak, daha düşük hesaplama maliyetiyle aynı problemi çözmeyi mümkün kılmaktadır (Felbo vd., 2017).

# İKİNCİ BÖLÜM

# MLP, LSTM-1DCNN, GRU, BILSTM İLE RÜZGAR HIZI VE YÖNÜN KOMPLEKS DÜZLEMDE KESTİRİMİ

Bu bölümde, kısa vadeli rüzgâr hızı ve yönünün tahminine yönelik olarak kompleks-değerli rüzgâr verilerinden faydalanan farklı derin öğrenme mimarilerinin uygulamaları ele alınmaktadır. Kompleks sayılar hem genlik hem de faz bileşenlerini birlikte ifade edebilmeleri sayesinde rüzgârın çok boyutlu doğasını tek bir veri yapısı içerisinde temsil etme avantajı sunar. Bu çalışmada, kompleks-değerli verilerin yapay sinir ağları ile uyumlu biçimde işlenebilmesi amacıyla, giriş verileri reel (gerçek) ve imajiner (karmaşık) bileşenlerine ayrıştırılarak ağ yapılarına sunulmuştur. Bu yaklaşım, hem fiziksel süreçlerin daha doğru modellenmesini hem de öğrenme sürecinde bağlamsal bilginin korunmasını hedeflemektedir. Şekil 2.1'de sunulan yapı, kompleks verilerin reel ve imajiner bileşenler halinde ayrılarak ağlara aktarılma sürecini şematik olarak göstermektedir. Bu şekilde, kompleks düzlemde taşınan bilgi, derin öğrenme yapılarının öğrenme kapasitesine entegre edilerek tahmin performansının artırılması amaçlanmıştır.

**Şekil 2.1.** *Kompleks-değerli verilerin standart ağ yapılarında kullanılmasına olanak sağlayan yapı*

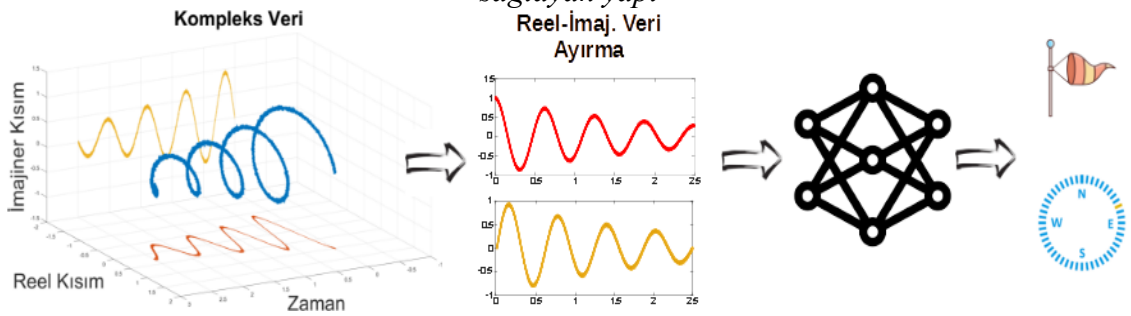

Bu doğrultuda, kısa vadeli rüzgâr tahmin performansını değerlendirmek amacıyla çok katmanlı algılayıcı (MLP), bir boyutlu evrişimsel sinir ağı (1D-CNN), uzun kısa süreli bellek (LSTM), çift yönlü lstm (BiLSTM), kapı kontrollü tekrarlayan birim (GRU) ve 1D-CNN + LSTM hibrit modeli olmak üzere altı farklı derin öğrenme mimarisi kullanılmıştır. Söz konusu modellerin mimari yapıları, öğrenme mekanizmaları ve eğitim süreçlerine ilişkin ayrıntılı bilgiler, bu bölümde alt başlıklar altında sunulmuştur. Ayrıca, kompleks-değerli rüzgâr sinyallerinin oluşturulmasına yönelik dönüşüm adımları, veri ön işleme süreci kapsamında Bölüm 2.1.'de detaylandırılmıştır.

## 2.1. Veri Ön İşleme

Bu çalışmada kullanılan derin öğrenme modellerine giriş olarak sağlanan rüzgâr verileri, ham biçimde reel-değerli hız ve yön bileşenlerinden oluşmaktadır. Ancak, çalışmanın temel yaklaşımı olan kompleks düzlem temsiline uygun olarak bu veriler, eğitim sürecine dahil edilmeden önce belirli dönüşüm adımlarından geçirilmiştir. Bu kapsamda, reel-değerli rüzgâr hızı ve yön bilgileri kullanılarak kompleks-değerli bir rüzgâr sinyali oluşturulmuştur. Bu sinyalin matematiksel ifadesi Denklem (2.1)'de verilmiştir.

$$x(k) = A_k e^{j\theta_k} \tag{2.1}$$

Burada, $A_k$ rüzgâr hızını, $\theta_k$ ise rüzgâr yönünü temsil etmektedir. Böylelikle, rüzgârın genlik (hız) ve faz (yön) bilgileri tek bir kompleks veri yapısı altında birleştirilmiştir.

Kompleks sinyallerin doğrudan sinir ağı modellerine aktarılması mümkün olmadığından, bu veriler iki ayrı bileşene ayrılarak ağ yapılarına sunulmuştur. Giriş verileri, reel (gerçek) ve imajiner (karmaşık) kısımlar olarak yeniden yapılandırılmış ve model giriş katmanlarına ayrı ayrı aktarılmıştır. Bu işlem, derin öğrenme mimarilerinin kompleks yapıda saklanan bilgileri ayrı boyutlarda işleyerek öğrenme sürecine entegre etmesini sağlamaktadır.

Ayrıca, modellerin eğitimi sırasında giriş verileri üzerinde normalize işlemi uygulanarak ölçek bağımlılığı ortadan kaldırılmış ve modelin öğrenme stabilitesi artırılmıştır. Bu bağlamda, veriler Min-Max normalizasyon yöntemi ile [0,1] aralığına ölçeklendirilmiştir. Eğitim ve test setleri ise zaman serisinin kronolojik yapısını koruyacak şekilde ayrılmıştır.

Veri ön işleme adımları sayesinde, hem giriş verilerinin kompleks yapısı yapay sinir ağı yapılarıyla uyumlu hale getirilmiş hem de tahmin süreçlerinin güvenilirliği ve doğruluğu artırılmıştır.

### 2.2. Çok Katmanlı Algılayıcı (MLP)

Çok katmanlı algılayıcılar (Multilayer Perceptrons – MLP), ileri beslemeli yapısı ve en az bir gizli katman içermesiyle, derin öğrenme alanında yaygın olarak kullanılan yapay sinir ağı modellerinden biridir. Bu mimari, doğrusal olmayan ilişkileri modelleyebilme yeteneği sayesinde, farklı tahminleme problemlerinde etkili bir şekilde kullanılmaktadır.

Bu çalışmada, kısa vadeli rüzgâr hızı ve yönünün tahmini amacıyla kompleks-değerli rüzgâr verilerinin analizinde MLP yapısından yararlanılmıştır. Model, geçmiş zamana ait sıralı rüzgâr verilerini giriş olarak alarak, bir sonraki zaman adımındaki rüzgâr bilgisini tahmin etmeye yöneliktir. Girdi olarak sunulan veri yapısı, N adet ardışık zaman adımına karşılık gelen kompleks-değerli sinyallerden oluşmakta olup, bu sinyaller daha önce Denklem (2.1) ile tanımlanan yapıya göre elde edilmektedir. Bu N adet veri aynı anda modele giriş olarak sunulmakta ve model, bu geçmiş örüntülerden yararlanarak gelecek adıma ilişkin kestirimde bulunmaktadır.

Kullanılan MLP mimarisi üç adet gizli katmandan oluşmakta olup, her bir katmanda 32 nöron bulunmaktadır. Model, bu çok katmanlı yapı sayesinde verilerdeki karmaşık ilişkileri öğrenerek, geleceğe yönelik tahminleme kapasitesini artırmaktadır. Çıkış katmanında ise kompleks-değerli sinyalin reel ve imajiner bileşenlerine karşılık gelen iki ayrı çıktı yer almaktadır. Bu yapı, modelin yalnızca rüzgâr hızını değil aynı zamanda yön bilgisini de dikkate alarak çok boyutlu tahmin yapabilmesine olanak sağlamaktadır.

Modelin mimari yapısını gösteren genel yapı Şekil 2.2.'de sunulmuştur. Modelin eğitim parametreleri ve hiperparametre yapılandırmalarına ilişkin ayrıntılar ise Üçüncü Bölüm'deBenzetim Sonuçları başlığı altında sunulmuştur.

**Şekil 2.2.** *Çok katmanlı algılayıcı (MLP) yapısı*

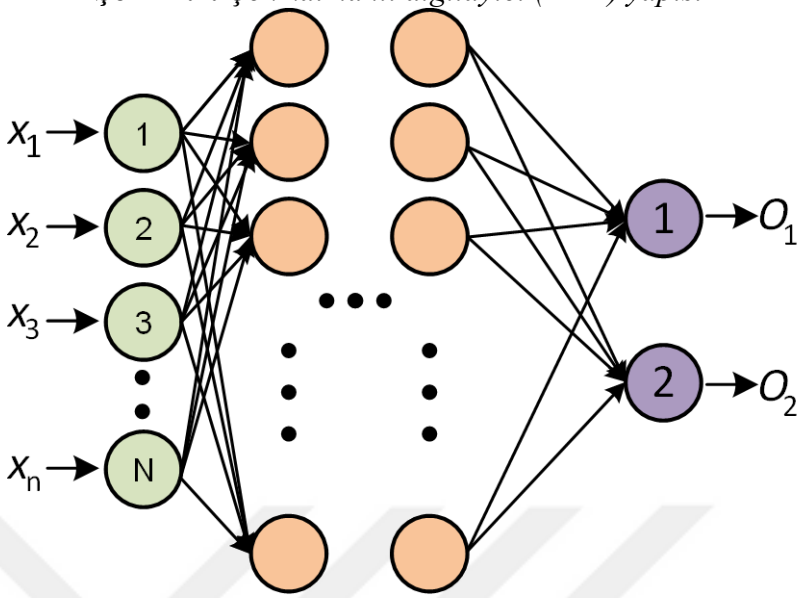


## 2.3. Bir Boyutlu Evrişimsel Sinir Ağları (1D-CNN)

Bir boyutlu evrişimsel sinir ağları (1D-CNN), özellikle zaman serisi verilerinin işlenmesinde yaygın olarak kullanılan bir derin öğrenme mimarisidir. Geleneksel evrişimli sinir ağı yapısıyla benzer prensiplere sahip olan bu modeller, girdi verisine bir boyutlu evrişim işlemi uygulayacak şekilde özel olarak tasarlanmıştır. Bu işlem, belirli bir pencere boyutuna sahip filtrelerin giriş verisi üzerinde kaydırılmasıyla gerçekleştirilmekte ve bu sayede verideki anlamlı örüntüler çıkarılmaktadır. 1D-CNN yapıları; zaman serisi tahmini, metin sınıflandırma ve ses işleme gibi çeşitli alanlarda etkin biçimde kullanılmaktadır.

Bu çalışmada, kısa vadeli rüzgâr hızı ve yönü tahmini amacıyla kompleks-değerli rüzgâr sinyallerinin analizinde 1D-CNN mimarisi kullanılmıştır. Model girişine, MLP yapısında olduğu gibi, Denklem (2.1) ile tanımlanan $N$ adet ardışık kompleks rüzgâr bilgisi sunulmuştur. Kompleks veriler, reel ve imajiner bileşenlerine ayrılarak ağ yapısına iki ayrı kanal olarak iletilmiştir. Böylece model, rüzgârın hem hız hem de yön bileşenlerini ayrı biçimlerde değerlendirerek tahminleme sürecini gerçekleştirmektedir.

Kurgulanan 1D-CNN yapısında üç adet gizli katman yer almakta olup, her bir katmanda 32 nöron bulunmaktadır. Evrişim işlemleri için filtre boyutu 3 olarak belirlenmiştir. Evrişim katmanlarında çıkarılan öznitelikler, sonrasında tam bağlantılı katmana aktarılmakta ve bu katmanda daha üst düzey temsillere dönüştürülmektedir. Modelin çıkış katmanında ise kompleks rüzgâr sinyaline ait reel ve imajiner bileşenler ayrı olarak

elde edilmektedir. Böylece model hem rüzgâr hızını hem de yönünü eş zamanlı olarak tahmin edebilecek biçimde yapılandırılmıştır.

Kullanılan 1D-CNN mimarisine ait genel şematik yapı Şekil 2.3.'te sunulmuştur.

**Şekil 2.3.** *Bir boyutlu evrişimsel sinir ağı (1DCNN) yapısı*

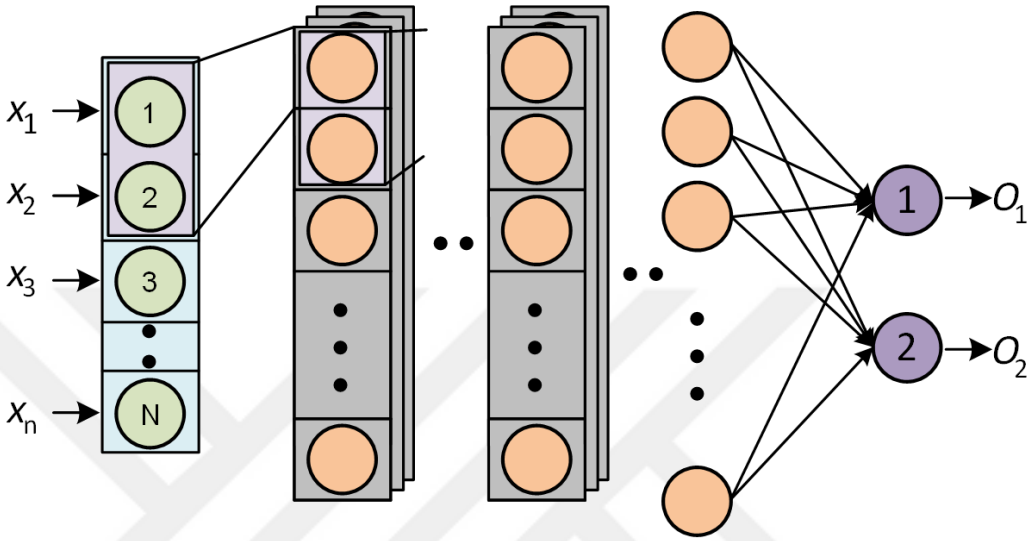


## 2.4. Uzun Kısa Süreli Bellek (LSTM)

Uzun kısa süreli bellek (Long Short-Term Memory – LSTM) ağları, zaman serisi verilerinde uzun vadeli bağımlılıkların modellenmesine olanak tanıyan gelişmiş bir derin öğrenme mimarisidir. Geleneksel yinelemeli sinir ağı (Recurrent Neural Network – RNN) yapısının sınırlamalarını aşmak amacıyla geliştirilen LSTM, bilgi akışını yöneten kapı mekanizmaları sayesinde geçmişten gelen bilgilerin hafızada etkin bir şekilde tutulmasını sağlamaktadır. LSTM hücresi; giriş kapısı, unutma kapısı, çıkış kapısı ve hücre durumu bileşenlerinden oluşmakta olup, bu yapı sayesinde modelin zaman içerisindeki örüntüleri öğrenme yetkinliği artırılmıştır. LSTM hücresinin genel yapısı Şekil 2.4'te sunulmuştur.

**Şekil 2.4.** *Uzun kısa süreli bellek (LSTM) hücresi*

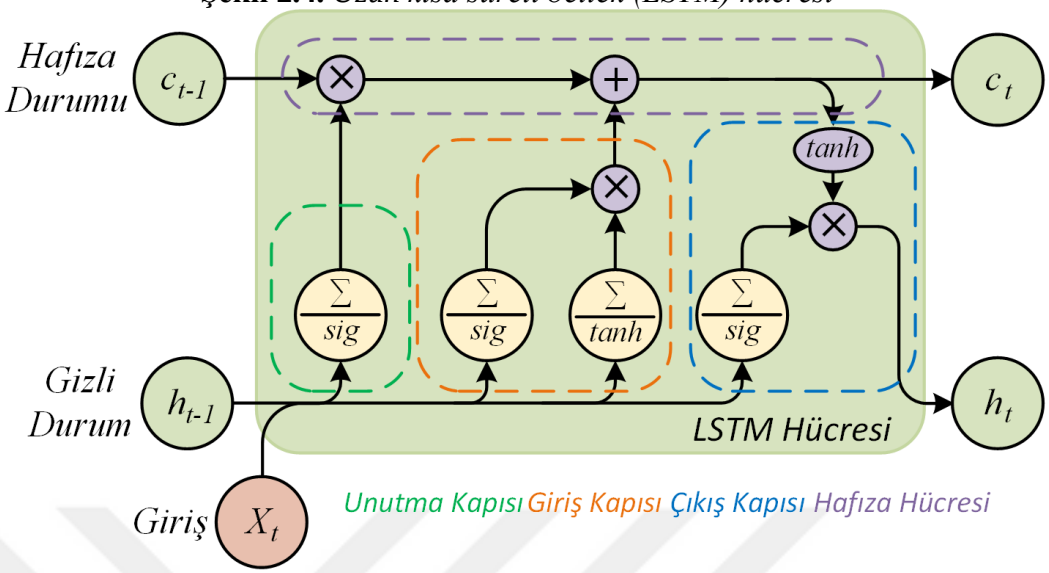


Bu çalışmada, kısa vadeli rüzgâr hızı ve yönü tahmini amacıyla kompleks-değerli rüzgâr verilerinin analizinde LSTM yapısı kullanılmıştır. MLP ve 1D-CNN modellerinden farklı olarak, LSTM mimarisi giriş verilerini zaman adımları halinde işlemektedir. Denklem (2.1) ile tanımlanan $N$ adet geçmiş zaman adımına karşılık gelen kompleks veriler, ağ yapısına sıralı biçimde tek tek giriş olarak sunulmuştur. Böylece, her zaman adımındaki veri LSTM hücresinde ayrı ayrı değerlendirilmiş ve zamansal ilişkiler modelin öğrenme sürecine entegre edilmiştir.

LSTM hücreleri tarafından öğrenilen öznitelikler, son zaman adımında tam bağlantılı katmana aktarılmış ve burada işlenerek kompleks rüzgâr sinyalinin reel ve imajiner bileşenlerine karşılık gelen iki ayrı çıktı elde edilmiştir. Bu yapı sayesinde, model hem rüzgâr hızını hem de yönünü eşzamanlı olarak tahmin edebilmektedir. Kullanılan LSTM mimarisine ait genel yapı Şekil 2.5.'te sunulmuştur.

**Şekil 2.5.** *Uzun kısa süreli bellek (LSTM) yapısı*

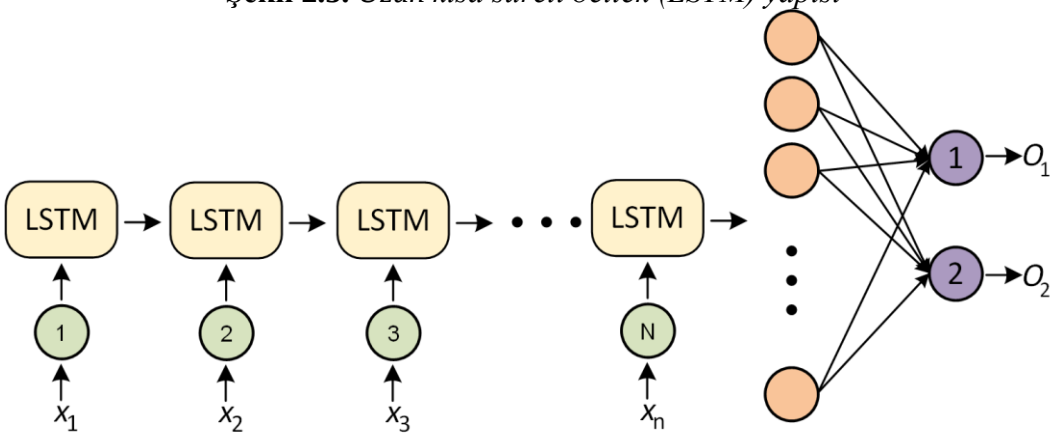


## 2.5. Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory – BiLSTM)

Çift yönlü uzun kısa süreli bellek (Bidirectional Long Short-Term Memory – BiLSTM) ağları, geleneksel LSTM yapısının ileri ve geri yönlü bilgi akışını eş zamanlı olarak modelleyebilme yeteneği ile geliştirilmiş bir derin öğrenme mimarisidir. Standart LSTM ağları yalnızca geçmiş zamana ait verileri değerlendirirken, BiLSTM modelleri giriş verisini hem zamanın ileri hem de geri yönünde işleyerek daha kapsamlı bir bağlamsal öğrenme sağlar. Bu yapı sayesinde model, sıralı verilerdeki örüntüleri hem geçmiş hem de gelecek ilişkiler üzerinden analiz ederek daha doğru tahminler yapabilmektedir.

BiLSTM modelleri, özellikle doğal dil işleme, konuşma tanıma ve zaman serisi tahmini gibi çift yönlü bağımlılıkların öğrenilmesinin önemli olduğu uygulama alanlarında etkin biçimde kullanılmaktadır. Bu çalışmada ise, kısa vadeli rüzgâr hızı ve yönü tahmini amacıyla BiLSTM mimarisi değerlendirilmiştir. Daha önce denklem (2.1) ile tanımlanan kompleks-değerli rüzgâr verileri, sıralı yapı korunarak modele giriş olarak sunulmuştur. $N$ adet geçmiş zaman adımına karşılık gelen kompleks veriler, ileri ve geri yönlü iki ayrı LSTM katmanı tarafından eşzamanlı olarak işlenmiştir. Böylece model hem geçmiş zaman adımlarındaki örüntüleri hem de gelecekteki yapısal ilişkileri dikkate alarak daha güçlü bir öğrenme gerçekleştirmiştir.

BiLSTM yapısında, her iki yönlü LSTM katmanından elde edilen öznitelikler birleştirilerek tam bağlantılı katmana aktarılmıştır. Bu katmanda, modelin öğrenmiş olduğu ileri ve geri yönlü bilgilere dayalı öznitelikler işlenmiş ve çıkış katmanında rüzgâr sinyalinin reel ve imajiner bileşenlerine karşılık gelen iki ayrı çıktı elde edilmiştir. Bu

yapı sayesinde, rüzgârın hem hız hem de yön bileşenleri kompleks düzlem üzerinde ayrı ayrı tahmin edilmiştir.

Kullanılan BiLSTM mimarisinin genel yapısı Şekil 2.6.'da sunulmuştur. Modelin eğitim süreçlerine ve hiperparametre yapılandırmalarına ilişkin ayrıntılar ise Üçüncü Bölüm'de Benzetim Sonuçları başlığı altında açıklanmıştır.

**Şekil 2.6.** *Çift yönlü LSTM yapısı (BiLSTM)*

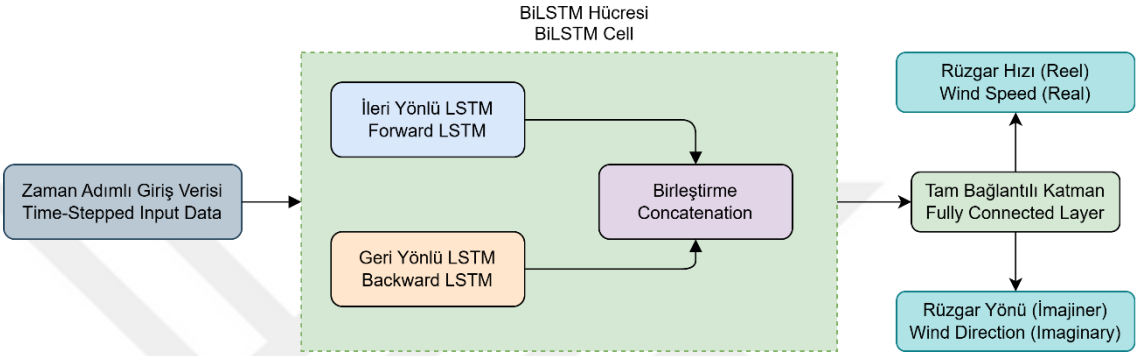


## 2.6. Kapı Kontrollü Tekrarlayan Birim (Gated Recurrent Unit – GRU)

Kapı kontrollü tekrarlayan birim (Gated Recurrent Unit – GRU) modelleri, yinelemeli sinir ağları (RNN) ailesine ait ve özellikle sıralı verilerdeki bağımlılıkların öğrenilmesi amacıyla geliştirilmiş yapılar arasında yer almaktadır. GRU mimarisi, LSTM ile benzer şekilde zaman serisi içerisindeki uzun vadeli ilişkileri modelleyebilme kabiliyetine sahiptir. Ancak LSTM'e kıyasla daha sade bir yapıya sahiptir ve hesaplama yükü açısından daha verimlidir. Bu yapıda, bilgi akışını kontrol eden güncelleme kapısı (update gate) ve reset kapısı (reset gate) olmak üzere iki temel kapı mekanizması bulunmaktadır. GRU'nun bu özelliği hem öğrenme sürecini hızlandırmakta hem de modelin genel performansını artırmaktadır.

Bu çalışmada, kompleks-değerli rüzgâr sinyallerinin tahmini amacıyla GRU mimarisi uygulanmıştır. Denklem (2.1) ile tanımlanan kompleks rüzgâr verileri, diğer zaman serisi modellerinde olduğu gibi geçmiş zamana ait $N$ adet bilgi içerecek şekilde yapılandırılmıştır. Bu veriler, sıralı biçimde GRU katmanlarına giriş olarak sunulmuş ve her bir zaman adımı GRU hücreleri tarafından işlenmiştir. Model, bu ardışık veriler üzerinden hem zamansal örüntüleri hem de veri içindeki yapısal ilişkileri öğrenmektedir.

GRU yapısında, giriş verilerinin işlenmesi sonucunda elde edilen öznitelikler, modelin son hücresinde toplanarak tam bağlantılı (fully connected) katmana aktarılmıştır. Bu

katmanda, çıkarılan öznitelikler kompleks rüzgâr sinyalinin reel ve imajiner bileşenlerine karşılık gelen iki ayrı çıktıya dönüştürülmüştür. Böylece, model hem rüzgâr hızını hem de yönünü eşzamanlı biçimde tahmin edebilecek şekilde yapılandırılmıştır.

**Şekil 2.7.** *GRU hücresinin iç yapısı*

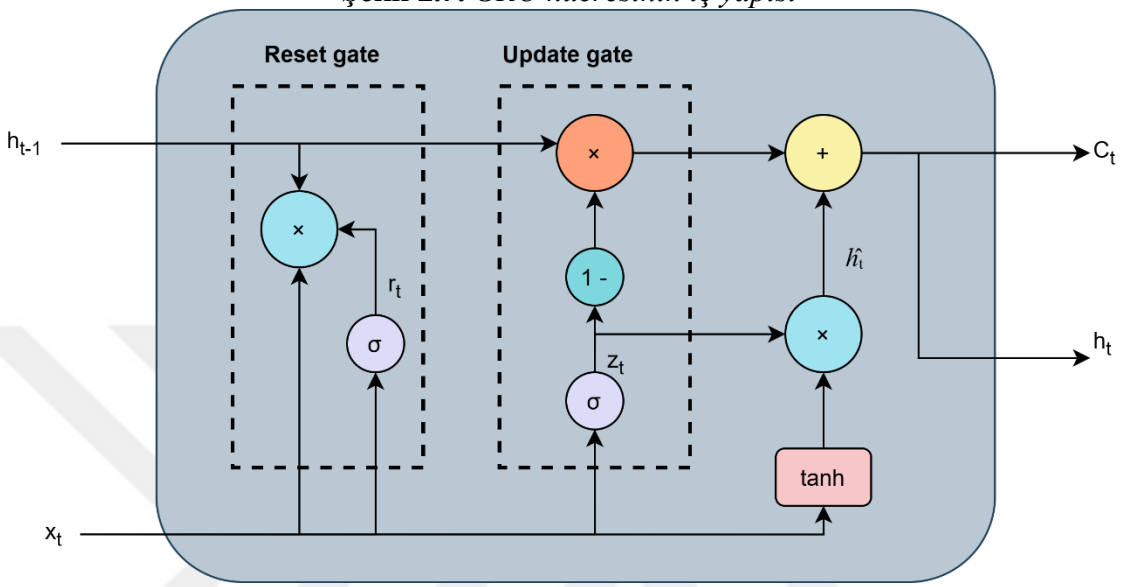


Kullanılan GRU mimarisine ait genel yapıya ilişkin şematik gösterim Şekil 2.7.'de sunulmuştur. Modelin eğitim parametrelerine ve hiperparametre yapılandırmalarına ilişkin detaylı bilgiler ise Üçüncü Bölüm'de Benzetim Sonuçları başlığı altında açıklanmıştır.

## 2.7. 1D-CNN + LSTM Hibrit Modeli ile Rüzgâr Tahmini

Bu çalışmada, rüzgâr hızı ve yönünün kısa vadeli tahminine yönelik olarak, bir boyutlu evrişimsel sinir ağı (1D-CNN) ile uzun kısa süreli bellek (LSTM) mimarilerinin birleşiminden oluşan bir hibrit model yapılandırılmıştır. Bu modelin temel amacı, 1D-CNN'in giriş verilerinden lokal öznitelikleri çıkarma yeteneğini, LSTM'in sıralı zaman adımlarındaki bağımlılıkları öğrenme kapasitesi ile birleştirerek daha yüksek tahmin doğruluğu elde etmektir. Böylece hem verinin zamansal örüntüleri hem de yapısal ilişkileri aynı model içerisinde işlenebilmektedir.

1D-CNN katmanları, girdi verisinin lokal yapısını filtreler aracılığıyla analiz ederken, LSTM katmanları bu filtrelenmiş özniteliklerin zamansal bağlamda işlenmesini sağlar. Bu tür birleşik modeller, literatürde özellikle karmaşık yapıya sahip zaman serilerinin analizinde yüksek performans göstermeleri nedeniyle yaygın olarak tercih edilmektedir.

Bu bağlamda, önerilen hibrit yapı rüzgâr tahminine yönelik kompleks düzlem temsiline dayalı modelleme yaklaşımına katkı sağlamaktadır.

Model girişine, önceki bölümlerde tanımlanan şekilde Denklem (2.1) ile ifade edilen kompleks-değerli rüzgâr sinyalleri sunulmuştur. Bu veriler, reel ve imajiner bileşenlerine ayrıştırılmış ve giriş katmanında ayrı kanallar olarak modele aktarılmıştır. İlk aşamada, 1D-CNN katmanları verinin lokal örüntülerini çıkarmış; bu öznitelikler daha sonra LSTM katmanlarına iletilmiştir. LSTM katmanları, çıkarılmış bu özellikleri zaman adımlarına göre sıralı olarak işleyerek modelin zaman içindeki bağlamı öğrenmesini sağlamıştır.

Hibrit model yapısında üç konvolüsyon (evrişim) katmanı kullanılmış olup, her birinde 32 filtre yer almaktadır. Evrişim işlemleri için filtre boyutu 3 olarak belirlenmiştir. CNN katmanlarından sonra uygulanan maksimum havuza alma (max pooling) işlemleriyle öznitelik haritaları boyut olarak sadeleştirilmiştir. Bu işlem sonrasında elde edilen öznitelikler sıralı bir biçimde LSTM katmanlarına aktarılmış ve burada zamansal öğrenme süreci tamamlanmıştır.

LSTM hücrelerinden elde edilen son öznitelikler, tam bağlantılı (fully connected) katmana iletilmiş ve burada işlenerek kompleks rüzgâr sinyalinin reel ve imajiner bileşenlerine karşılık gelen iki ayrı çıktı elde edilmiştir. Bu sayede model, rüzgârın hem hız hem de yön bileşenlerini kompleks düzlemde eşzamanlı olarak tahmin edebilmiştir.

Modelin eğitim süreçleri ve hiperparametre yapılandırmalarına ilişkin detaylı açıklamalar ise Üçüncü Bölüm’de Benzetim Sonuçları başlığı altında sunulmuştur.

# ÜÇÜNCÜ BÖLÜM
# BENZETİM SONUÇLARI VE TARTIŞMA

Bu bölümde, önerilen derin öğrenme mimarilerinin kısa vadeli rüzgâr hızı ve yönü tahminindeki başarımları detaylı bir şekişlde analiz edilmiştir. İlk olarak, modellerin eğitimi ve testinde kullanılan veri setine ve çalışma ortamına ilişkin ayrıntılar sunulmuştur. Ardından, verilerin ön işleme süreci kapsamında gerçekleştirilen normalizasyon adımları ve eğitim-test seti ayırımı özetlenmiştir. Devamında, model başarımlarını değerlendirmek amacıyla kullanılan metrikler ve istatistiksel performans kriterleri açıklanmıştır. Son bölümde ise, tüm derin öğrenme modellerine ait benzetim sonuçları karşılaştırmalı olarak sunulmuş ve elde edilen çıktılar tartışılmıştır.

## 3.1. Veri Seti ve Çalışma Ortam Tanımı

Bu çalışmada kullanılan rüzgâr veri seti, Washington Eyaleti'ndeki hava durumu istasyonları tarafından kaydedilen otomatik meteorolojik ölçümlerden elde edilmiştir. Veriler, Automated Weather Observing Systems (AWOS) tarafından sağlanmış olup, rüzgâr hızı ve yönü gibi çeşitli atmosferik parametrelerin düzenli aralıklarla ölçümünü içermektedir (AWOS, 2010). Analizlerde, 2010 yılına ait Şubat ve Aralık aylarını kapsayan iki farklı dönemden alınan veri setleri kullanılmıştır. Söz konusu veri kümeleri, her biri bir aylık süreyi kapsamakta olup, bir dakikalık zaman aralıklarında ölçülmüş rüzgâr verilerinden oluşmaktadır. Analiz sürecinde, şubat ve aralık aylarına ait bu veri setleri, sunum kolaylığı sağlamak amacıyla sırasıyla VeriSeti1 ve VeriSeti2 olarak adlandırılmıştır. Kullanılan veri setleri, ağlara giriş olarak uygulanmadan önce yüksek frekanslı gürültülerin etkisini azaltmak amacıyla ön işleme tabi tutulmuştur. Kullanılan veri setleri, ağlara giriş olarak uygulanmadan önce yüksek frekanslı gürültülerin etkisini azaltmak amacıyla ön işleme tabi tutulmuştur. Bu kapsamda, ham rüzgâr verilerine 100.

dereceden hareketli ortalama filtresi uygulanarak sinyaldeki ani dalgalanmalar yumuşatılmıştır. Tahmin görevine yönelik olarak verilerin sıralı yapısı göz önünde bulundurularak, her bir veri setinin %70'i eğitim verisi, kalan %30'u ise test verisi olarak ayrılmıştır.

Tüm benzetim çalışmaları, MATLAB R2023a yazılımı kullanılarak, AMD Ryzen 7 4800HS 2.9 GHz işlemciye, 16 GB RAM'e ve NVIDIA GeForce GTX 1650 Ti ekran kartına sahip bir kişisel bilgisayarda gerçekleştirilmiştir.

Ağ yapılarının eğitimi için Adam optimizasyon algoritması kullanılmıştır. Her bir yapı için 1000 epokluk bir eğitim süreci gerçekleştirilmiş olup, başlangıç öğrenme oranı 0.05 olarak belirlenmiştir. Öğrenme oranı, her 125 epokta 0.5 katsayısı ile otomatik olarak ölçeklendirilmiştir. Tüm ağ yapıları için eğitim ve test işlemleri 11 kez tekrarlanmıştır ve elde edilen sonuçların ortalama değerleri hesaplanmıştır. Bu kapsamda sıralı bir şekilde verilen mimarilerin başarımları ve verimlilikleri karşılaştırılmıştır. Çok katmanlı algılayıcı (MLP), bir boyutlu evrişimsel sinir ağı (1D-CNN), uzun kısa süreli bellek (LSTM), çift yönlü lstm (BiLSTM), kapı kontrollü tekrarlayan birim (GRU) ve 1D-CNN + LSTM.

### 3.2. Başarım Metrikleri

Ağların çıktılarında ürettikleri rüzgâr sinyallerine ait reel (hız) ve imajiner (yön) bileşenlerin tahmin doğrulukları ile hesaplama verimlilikleri değerlendirilerek karşılaştırılmıştır. Tahmin doğruluklarının ölçülmesi amacıyla elde edilen çıktılar iki farklı yöntemle test edilmiştir. Söz konusu yöntemler, sırasıyla Denklem (3.1a) ve Denklem (3.1b)'te tanımlanan standart tahmin kazancı (Standard Prediction Gain, $R_p$) ve korelasyon katsayısı (Correlation Coefficient, $CC$) olarak belirlenmiştir.

$$R_p(dB) = 10\ \log_{10}\left(\sigma_d^2 \Big/ \sigma_e^2\right) \tag{3.1a}$$

$$CC = \frac{cov(d,y)}{\sigma_d \sigma_y} \tag{3.1b}$$

Burada $d$ ifadesi gerçek rüzgâr verilerini temsil ederken, $y$ ifadesi tahmin edilen rüzgâr verilerini ifade etmektedir. Hata sinyali ise $e = d - y$ şeklinde hesaplanmaktadır. Gerçek

rüzgâr sinyali $d$'nin varyansı $\sigma_d^2$ olarak tanımlanırken, hata sinyalinin varyansı $\sigma_e^2$ ile tanımlanmaktadır. Ayrıca, $cov$ ise kovaryans fonksiyonunu temsil etmektedir.

### 3.3. Deneysel Sonuçlar

VeriSeti1 ve VeriSeti2'ye yönelik olarak, farklı yöntemler kullanılarak rüzgâr sinyali tahmini gerçekleştirilmiştir. Bu kapsamda, çok katmanlı algılayıcı (MLP)**,** bir boyutlu evrişimsel sinir ağı (1D-CNN)**,** uzun kısa süreli bellek (LSTM)**,** çift yönlü lstm (BiLSTM), kapı kontrollü tekrarlayan birim (GRU) ve 1D-CNN + LSTM hibrit modeli değerlendirmeye alınmıştır. Elde edilen sonuçlar Tablo 3.1 ve Tablo 3.2'de sunulmaktadır. Söz konusu tablolarda, ilk sütun tahmin yöntemlerini göstermekte olup, ikinci ve üçüncü sütunlarda modellerin eğitim süreçlerine ilişkin bilgiler yer almaktadır. Bu bilgiler, her bir modelin 1000 epokluk eğitimi tamamlama süresi ve eğitim sürecinin son epokuna ait kayıp (loss) değerini kapsamaktadır. Tablo içerisinde yer alan diğer sütunlar, test veri kümesi üzerinden elde edilen performans ölçütlerine karşılık gelmektedir. Bu sütunlarda sunulan değerlendirmeler, rüzgâr sinyali tahminine ilişkin olarak hesaplanan standart tahmin kazancı **(**$R_p$**)** ve korelasyon katsayısı **(**$CC$**)** değerlerinden oluşmaktadır.

**Tablo 3.1.** *VeriSeti1'de elde edilen sonuçlar*

| **Metot** | **Eğit. Süresi(dk)** | **Kayıp Değ.** | $R_p$**(Reel)** | $R_p$**(İm)** | $CC$ |
|---|---|---|---|---|---|
| MLP | 0:56 | 1.28E-03 | 33.6136 | 31.8468 | 0.99971 |
| 1DCNN | 0:59 | 9.91E-04 | 34.2742 | 32.5565 | 0.99977 |
| LSTM | 10:56 | 9.39E-04 | 35.5151 | 33.3067 | 0.99982 |
| 1DCNN+LSTM | 13:10 | 2.67E-05 | 35.0152 | 36.9499 | 0.99983 |
| BiLSTM | 18:23 | 2.13 E-05 | 37.3178 | 37.8593 | 0.99985 |
| GRU | 7:25 | 9.129E-04 | 35.5950 | 33.5030 | 0.9998998 |

**Tablo 3.2.** *VeriSeti2'de elde edilen sonuçlar*

| **Metot** | **Eğit. Süresi(dk)** | **Kayıp Değ.** | $R_p$**(Reel)** | $R_p$**(İm)** | $CC$ |
|---|---|---|---|---|---|
| MLP | 1.02 | 1.80E-03 | 31.9815 | 31.5534 | 0.99967 |
| 1DCNN | 1.05 | 1.50E-03 | 32.5049 | 32.02293 | 0.99971 |
| LSTM | 10:58 | 1.50E-03 | 33.4051 | 33.2129 | 0.99979 |
| 1DCNN+LSTM | 13:15 | 1.6E-04 | 36.6502 | 36.0038 | 0.99982 |
| BiLSTM | 18:38 | 2.58E-05 | 38.9523 | 37.6717 | 0.99987 |
| GRU | 7.28 | 1.48 E-03 | 32.9871 | 32.7719 | 0.99976 |

Tablo 3.1. ve Tablo 3.2.'de sunulan sonuçlar dikkate alındığında, yöntemlerin eğitim süreleri açısından karşılaştırmalı bir değerlendirmesi yapılmıştır. Elde edilen verilere göre, Çok katmanlı algılayıcı (MLP) modeli, diğer yöntemlere kıyasla en kısa eğitim süresine sahip model olarak öne çıkmaktadır. Bununla birlikte, bir boyutlu evrişimsel sinir ağı (1D-CNN) yapısının eğitim süresi MLP'ye oldukça yakın bir düzeyde gerçekleşmiştir. GRU yapısının daha sade yapısının etkisiyle LSTM ve BiLSTM yapılarıyla karşılaştırıldığında daha kısa sürede eğitilebilmekte ve bu yönüyle hesaplama verimliliği sağlamaktadır. 1D-CNN + LSTM hibrit modeli, her iki yapının avantajlarını birleştirerek hem doğruluk hem de eğitim süresi bakımından dengeli bir performans sunmaktadır. BiLSTM modeli ise, çift yönlü bilgi işleme yeteneğine sahip olması nedeniyle en uzun eğitim süresine sahip yöntem olarak öne çıkmaktadır. Bu bulgular, modellerin yapısal karmaşıklıklarının eğitim süresi üzerinde doğrudan etkili olduğunu göstermektedir.

Kayıp değerleri açısından gerçekleştirilen karşılaştırmalar, modellerin öğrenme süreçlerindeki başarım düzeylerine ilişkin önemli bir gösterge sunmaktadır. 1D-CNN ve LSTM modelleri, düşük kayıp değerleri ile benzer başarımlar sergileyerek, hedef değişkeni öğrenme açısından istikrarlı sonuçlar ortaya koymuştur. BiLSTM modeli de bu iki yöntemle kıyaslanabilir düzeyde düşük kayıp değeri elde ederek öğrenme performansında tatmin edici bir sonuç göstermiştir. GRU modeli ise görece daha yüksek bir kayıp değeriyle değerlendirilmiş, ancak hesaplama maliyeti düşük olan yapısı göz önüne alındığında bu değer kabul edilebilir düzeyde kalmıştır. MLP modeli, diğer yöntemlerle kıyaslandığında en yüksek kayıp değerine sahip yapı olarak öne çıkmıştır ve bu durum modelin daha sınırlı bir öğrenme kapasitesine işaret etmektedir. 1D-CNN + LSTM hibrit modeli, birleşik mimari yapısına rağmen düşük kayıp değeri ile güçlü bir öğrenme başarımı sergilemiştir. Kayıp değeri, bir modelin hedef çıktıyı ne ölçüde doğru tahmin ettiğini yansıtan temel bir başarı kriteri olmakla birlikte, model performansının bütüncül değerlendirilmesinde tek başına yeterli değildir. Bu nedenle, kayıp değerlerinin yanında $R_{\mathrm{p}}$ ve $CC$ gibi diğer istatistiksel başarı ölçütlerinin de dikkate alınması, model seçimini daha sağlıklı ve güvenilir hale getirmektedir.

Test veri kümesi üzerinde hesaplanan standart tahmin kazancı ($R_{\mathrm{p}}$) ve korelasyon katsayısı ($CC$) değerleri doğrultusunda yapılan değerlendirmeler, LSTM modelinin her iki başarı metriği açısından en yüksek tahmin performansını sergilediğini ortaya

koymaktadır. Bununla birlikte, 1D-CNN yapısı da LSTM ile karşılaştırılabilir düzeyde başarılı sonuçlar üretmiş ve test verisi üzerinde yüksek $R_{\mathrm{p}}$ ve $CC$ değerleri elde etmiştir. BiLSTM modeli, çift yönlü öğrenme kabiliyeti sayesinde LSTM ile benzer doğruluk seviyelerinde sonuçlar vermiştir. GRU mimarisi ise bu metrikler açısından BiLSTM'e yakın ancak biraz daha düşük başarımlar göstermiştir. MLP yöntemi, test başarı ölçütleri bakımından diğer modellere kıyasla daha düşük $R_{\mathrm{p}}$ ve $CC$ değerlerine ulaşmış ve bu durum, modelin sınırlı genel performansını yansıtmıştır. Eğitim süresi açısından en hızlı model olmasına rağmen, MLP'nin hem daha yüksek eğitim kayıp değeri hem de daha düşük test başarımı sergilemesi, bu modelin tahmin doğruluğu açısından dezavantajlı olduğunu göstermektedir. 1D-CNN + LSTM hibrit modeli, güçlü yapısal birleşimi sayesinde test seti üzerinde yüksek $R_{\mathrm{p}}$ ve $CC$ değerleriyle öne çıkmakta, böylece hem doğruluk hem de model genelleme kapasitesi açısından etkileyici bir performans ortaya koymaktadır. Özellikle 1D-CNN, hem eğitim süresi hem de tahmin doğruluğu bakımından LSTM'e kıyasla daha verimli bir yapı sunarak, uygulama açısından dengeli bir alternatif olduğunu göstermektedir. Elde edilen bu sonuçlar, kompleks-değerli rüzgâr verileri ile çalışan derin öğrenme modellerinin kısa vadeli rüzgâr tahmini görevlerinde yüksek potansiyel taşıdığını ve bu modellerin gelecekteki uygulamalar için değerli araçlar olabileceğini ortaya koymaktadır.

Sonuç olarak, gerçekleştirilen deneysel analizler doğrultusunda elde edilen bulgular, önerilen derin öğrenme mimarilerinin kompleks-değerli rüzgâr verileri ile etkili biçimde çalışabildiğini göstermiş ve rüzgâr hızı ile yönü tahmininde yüksek doğruluk sağlayabilecek modellerin belirlenmesine olanak tanımıştır.

### 3.4. Çok Katmanlı Algılayıcı (MLP) Modeli ile Kompleks-Değerli Rüzgâr Tahmin Performansı

Bu bölümde, MLP modeli kullanılarak gerçekleştirilen rüzgâr hızı (reel bileşen) ve yönü (imajiner bileşen) kısa vadeli tahminler performansı, grafiksel olarak iki farklı veri kümesi üzerinde (VeriSeti1 ve VeriSeti2) değerlendirilmiştir. VeriSeti1 ve VeriSeti2 üzerinde elde edilen sonuçlar Şekil 3.1. ve Şekil 3.2.'de verilmiştir. Karşılaştırma işleminde ilk olarak MLP modeli kullanılarak tahmin edilen değerlerler ile beklenen değerler hem reel hemde imajiner eksennde üst üste çizdidirilmiştir (Şekil 3.1.(a), Şekil 3.1.(c), Şekil 3.2.(a) ve Şekil 3.2.(c).) Şekillerde de görüleceği üzere her iki değerde birbirine çok yakın oldukları için hataların daha net gözlemlenebilmesi amacıyla hem reel

hemde imajiner bileşenler için hata değerlerini gösteren grafiklerde eklenmiştir (Şekil 3.1.(b), Şekil 3.1.(d), Şekil 3.2.(b) ve Şekil 3.2.(d)). Bu hata grafiklerinden elde edilen gözlemler, MLP modelinin genel eğilimleri başarılı bir şekilde takip ettiğini ancak ani değişimlerin olduğu bazı bölgelerde küçük sapmalar yaşadığını ortaya koymaktadır. Hem reel hem de imajiner bileşenler için hata genlikleri ±0.2 sınırları içerisinde kalmakta olup, bu durum modelin tahmin hatalarının düşük seviyede olduğunu göstermektedir. Ayrıca, hata sinyallerinin rastlantısal bir dağılım sergilemesi, modelin sistematik bir önyargıya sahip olmadığını ve genelleme kapasitesinin güçlü olduğunu desteklemektedir.

**Şekil 3.1.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları (a) reel eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

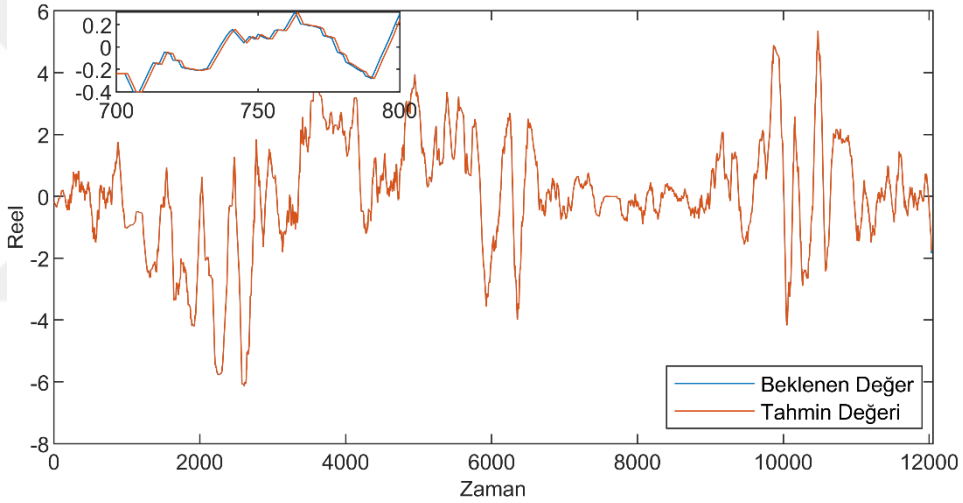


(a)

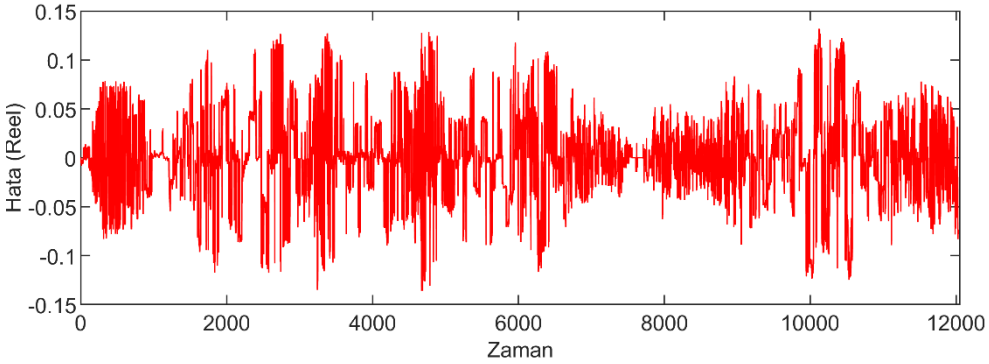


(b)

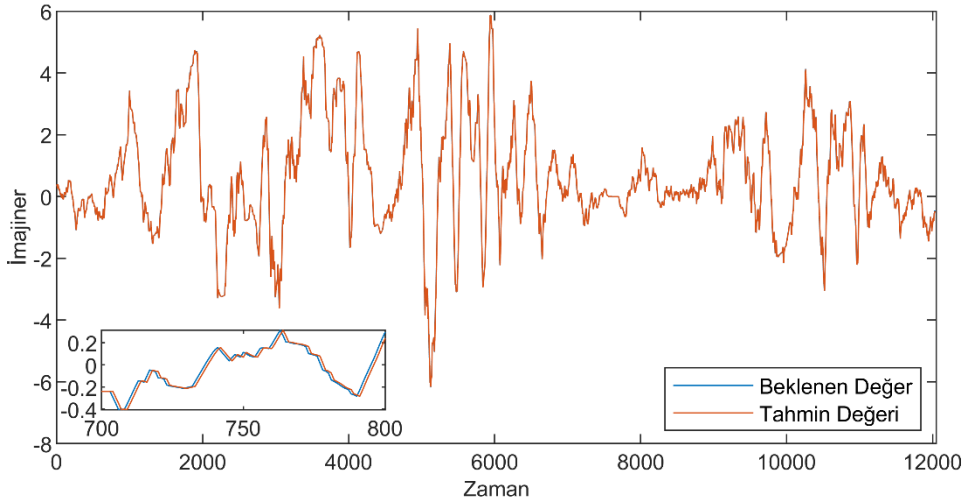


(c)

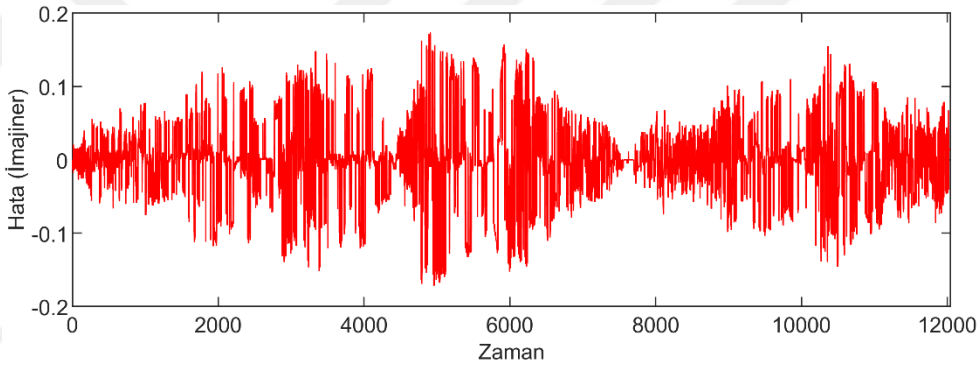


(d)

**Şekil 3.2.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve MLP modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

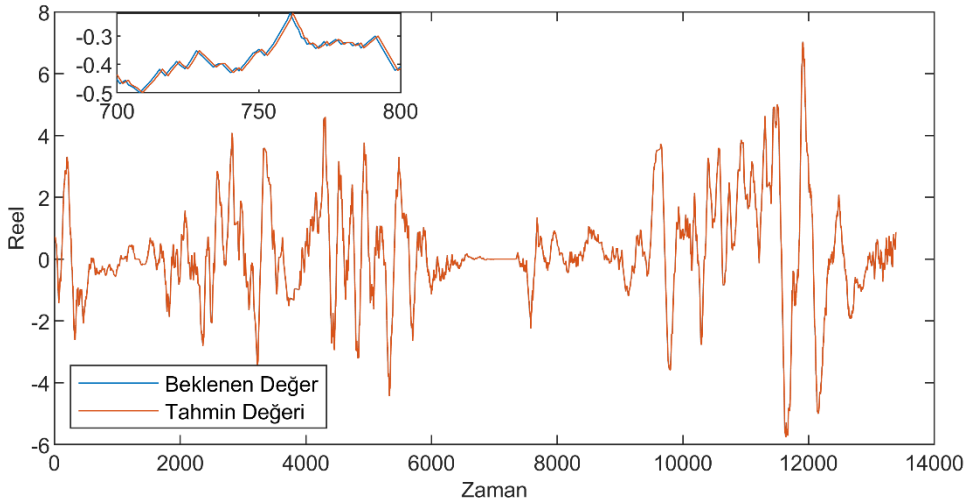


(a)

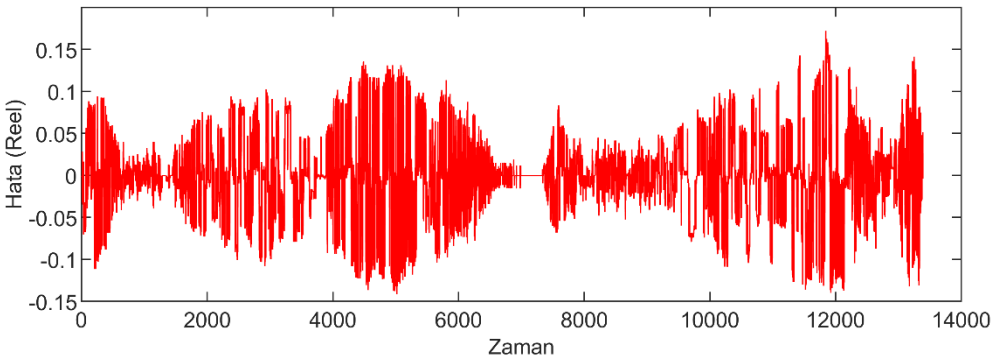
Hata (Reel)
Zaman
0.15
0.1
0.05
0
-0.05
-0.1
-0.15
0
2000
4000
6000
8000
10000
12000
14000

(b)

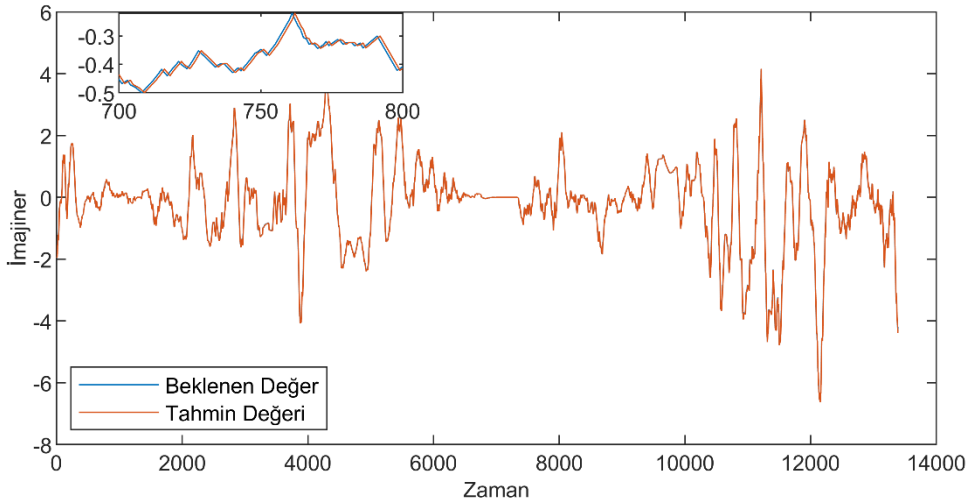
İmajiner
Zaman
Beklenen Değer
Tahmin Değeri
-0.3
-0.4
-0.5
700
750
800
6
4
2
0
-2
-4
-6
-8
0
2000
4000
6000
8000
10000
12000
14000

(c)

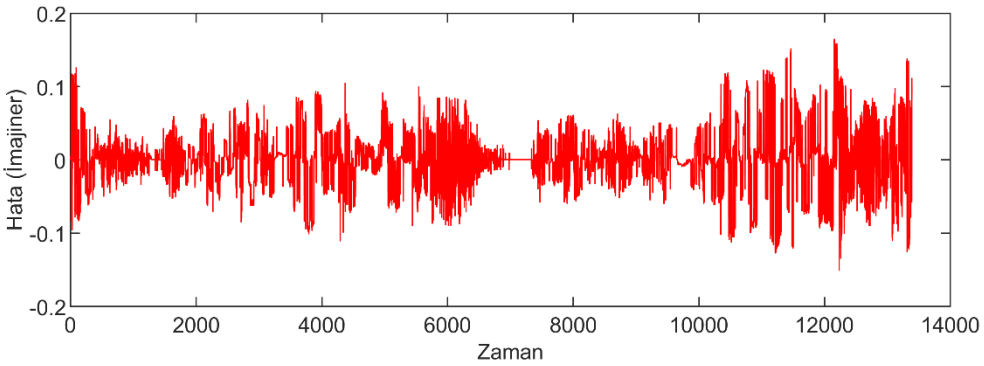
Hata (İmajiner)
Zaman
0.2
0.1
0
-0.1
-0.2
0
2000
4000
6000
8000
10000
12000
14000

(d)

**Şekil 3.3.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile MLP modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği*

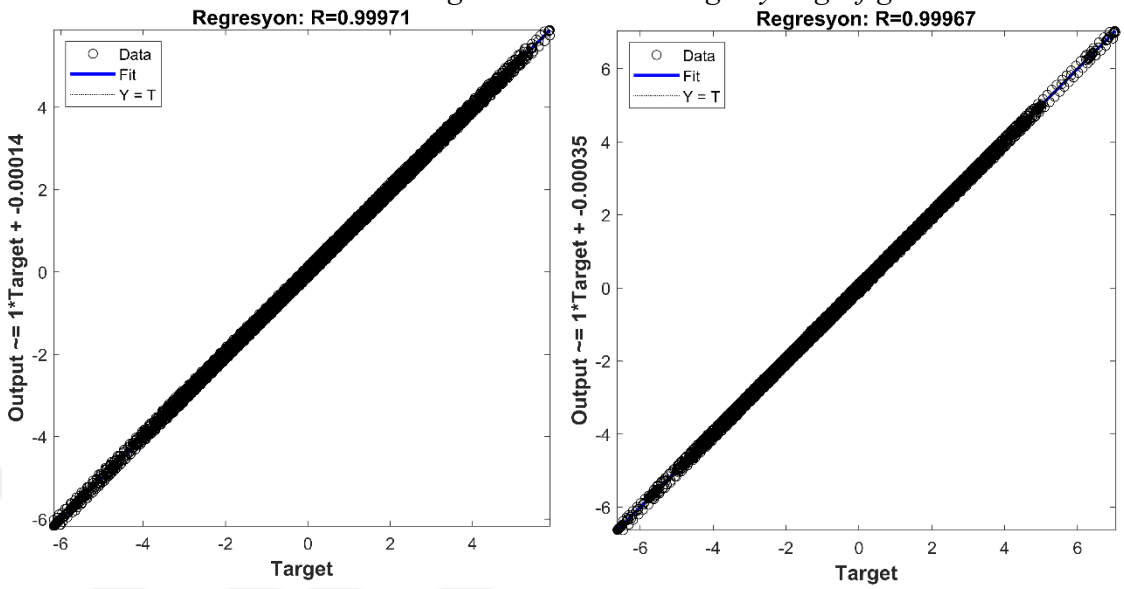


(a) (b)

### 3.5. Tek Boyutlu Konvolüsyonel Sinir Ağı (1D-CNN) Modeli ile Kompleks-Değerli Rüzgâr Tahmin Performansı

Bu bölümde, 1D-CNN tabanlı modelin kısa vadeli kompleks-değerli rüzgâr tahmini üzerindeki başarımı değerlendirilmiştir. Modelin performansı, daha önce kullanılan VeriSeti1 ve VeriSeti2 üzerinde ayrı ayrı analiz edilmiştir. Tahmin edilen reel ve imajiner bileşenler, beklenen değerlerle birlikte grafiksel olarak gösterilmiş; hata sinyalleri ile desteklenmiştir (Şekil 3.4. ve Şekil 3.5.).

Şekil 3.4.(a) ve Şekil 3.4.(c) ile Şekil 3.5.(a) ve Şekil 3.5.(c), sırasıyla reel ve imajiner eksenlerdeki tahmin ve gerçek sinyallerin üst üste çizimlerini içermektedir. Bu çizimlerden modelin genel eğilimleri oldukça başarılı bir şekilde takip ettiği gözlemlenmektedir. Buna ek olarak, hata sinyallerine ait grafikler (Şekil 3.4.(b), 3.4.(d), 3.5.(b), 3.5.(d)) aracılığıyla modelin belirli bölgelerdeki sapma düzeyleri incelenmiştir.

**Şekil 3.4.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

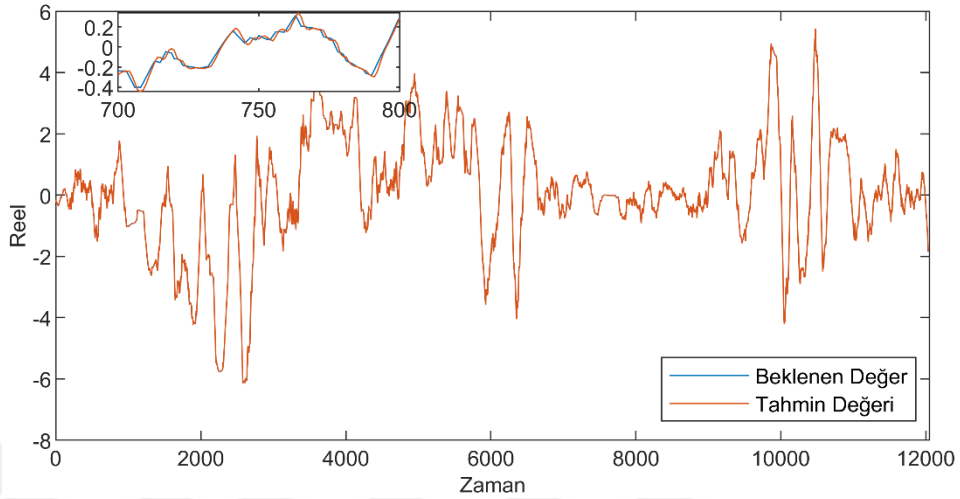


(a)

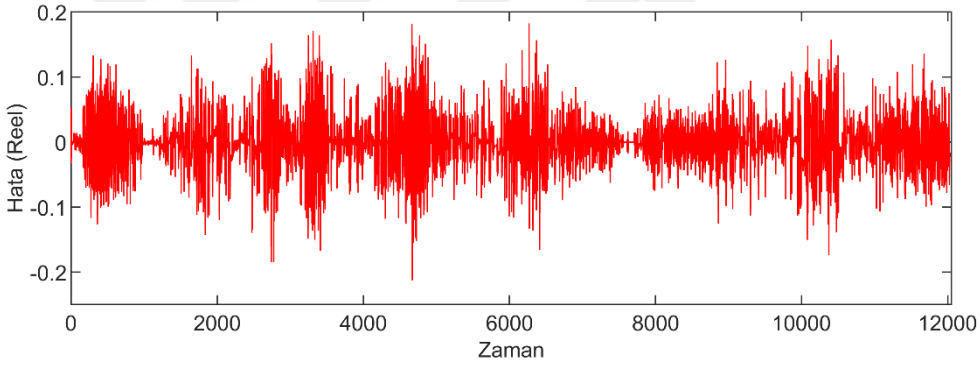


(b)

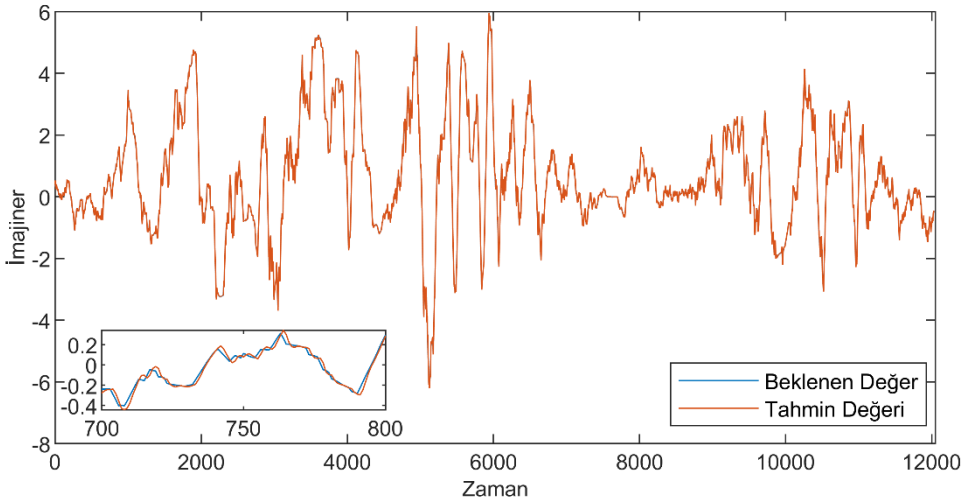


(c)

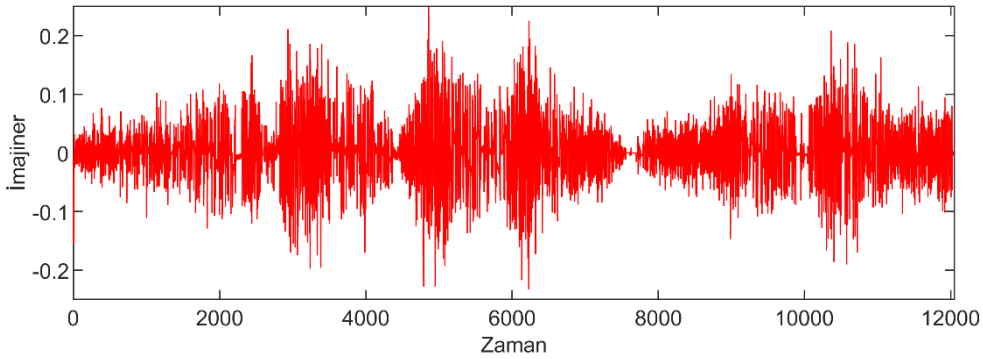


(d)

**Şekil 3.5.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

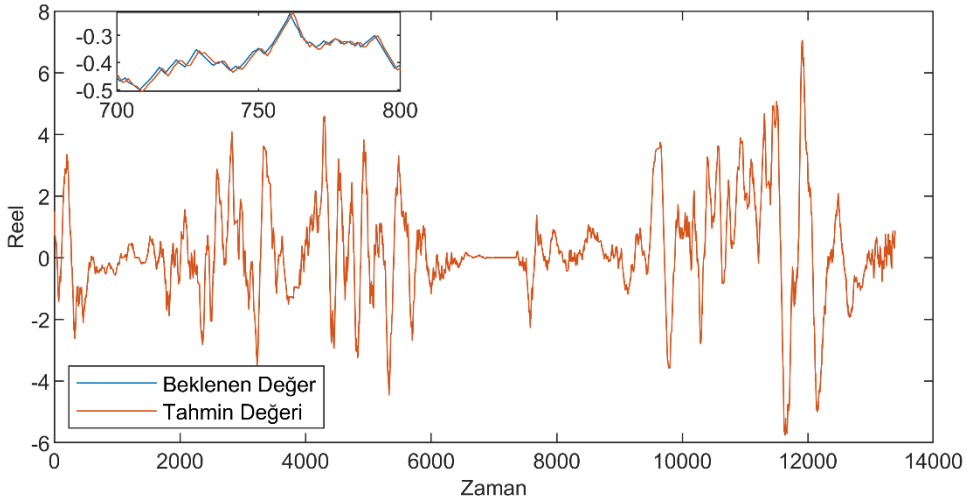


(a)

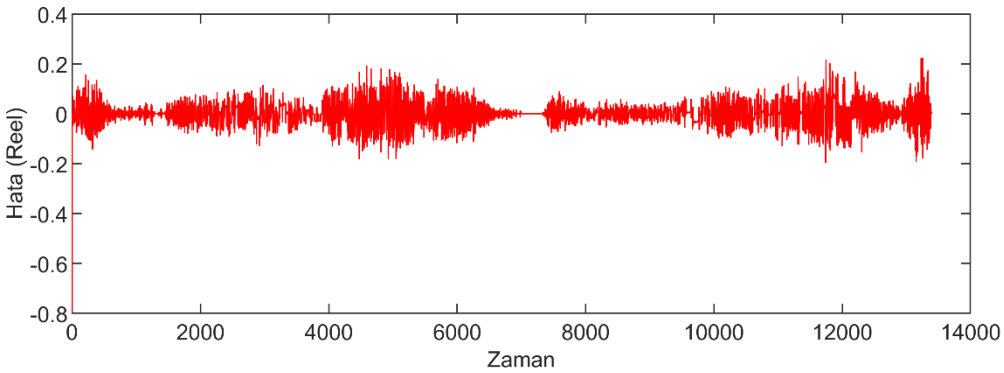


(b)

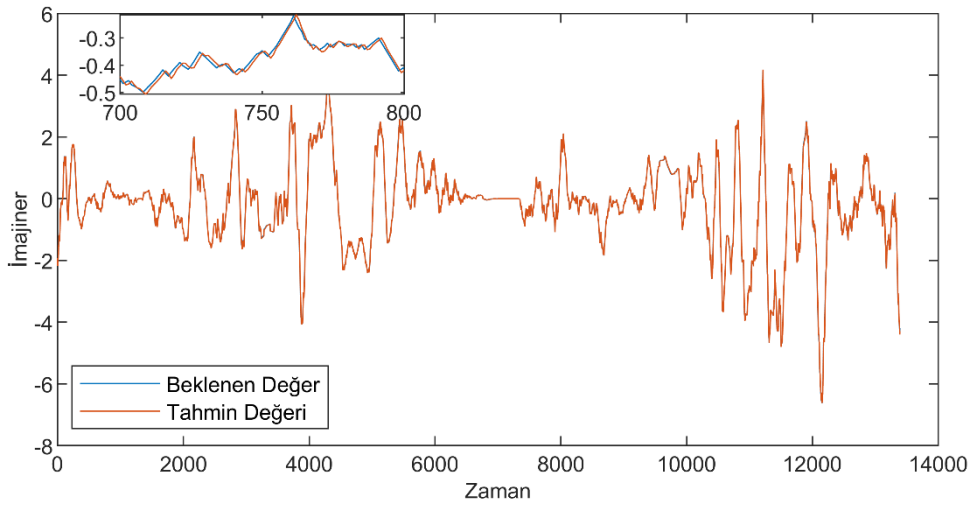


(c)

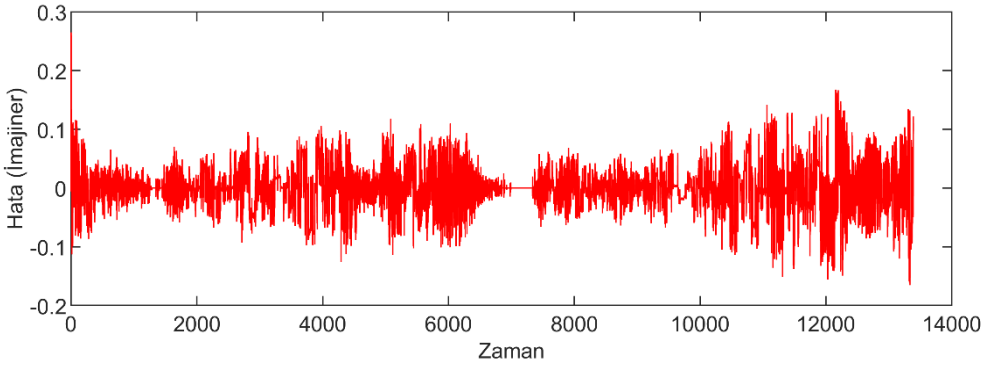


(d)

Ek olarak, tahmin performansının nicel analizi için regresyon grafikleri sunulmuş ve korelasyon katsayısı hesaplanmıştır (Şekil 3.6.). Elde edilen R değerleri ortaşamaları ise sırasıyla VeriSeti1 için 0.99981 ve VeriSeti2 için 0.99974 olarak belirlenmiştir.

**Şekil 3.6.** *VeriSeti1(a) ve VeriSeti2'de(b) gerçek değerler ile 1D-CNN modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği*

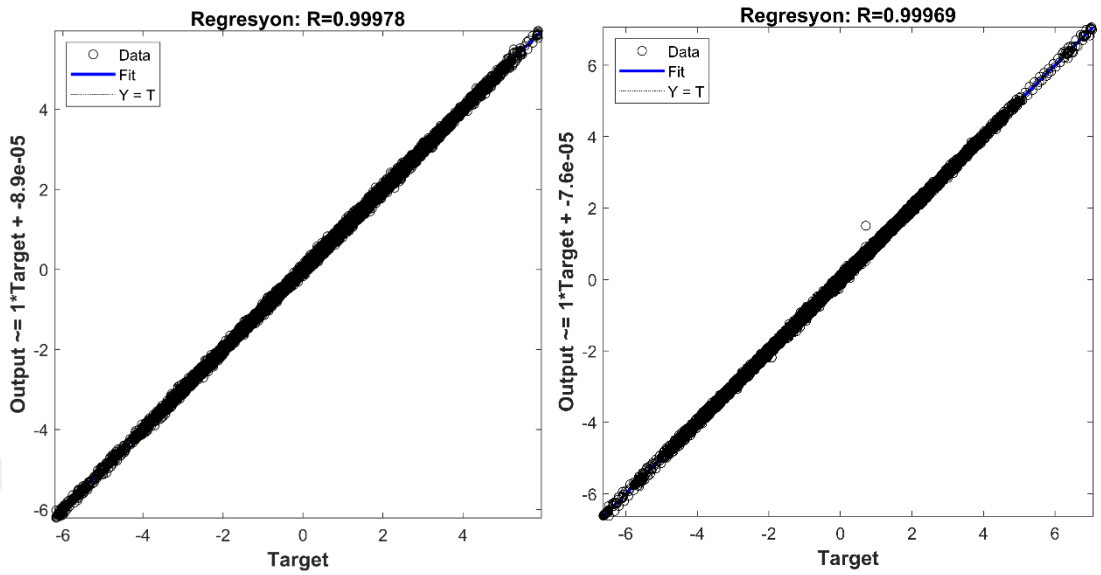


(a) (b)

### 3.6. Uzun Kısa Süreli Bellek (LSTM) Ağı ile Kompleks-Değerli Rüzgâr Tahmin Performansı

Zamana bağlı verilerin işlenmesinde yaygın olarak kullanılan LSTM ağı, bu çalışmada rüzgâr sinyallerinin kısa vadeli tahmini amacıyla değerlendirilmiştir. Giriş verilerindeki ardışıklığı dikkate alan bu yapı, özellikle geçmiş bilginin uzun süre korunabilmesi ile öne çıkmaktadır. VeriSeti1 ve VeriSeti2 üzerindeki tahmin sonuçları Şekil 3.7. ve Şekil 3.8.'de sunularak hem tahmin ve gerçek sinyaller hem de hata değerleri grafiksel olarak verilmiştir. Ayrıca, Şekil 3.9.'da de VeriSeti1 ve VeriSeti2 üzerinde gerçekleştirilen regresyon analizlerine ait sonuçlarda sunulmuştur.

**Şekil 3.7.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

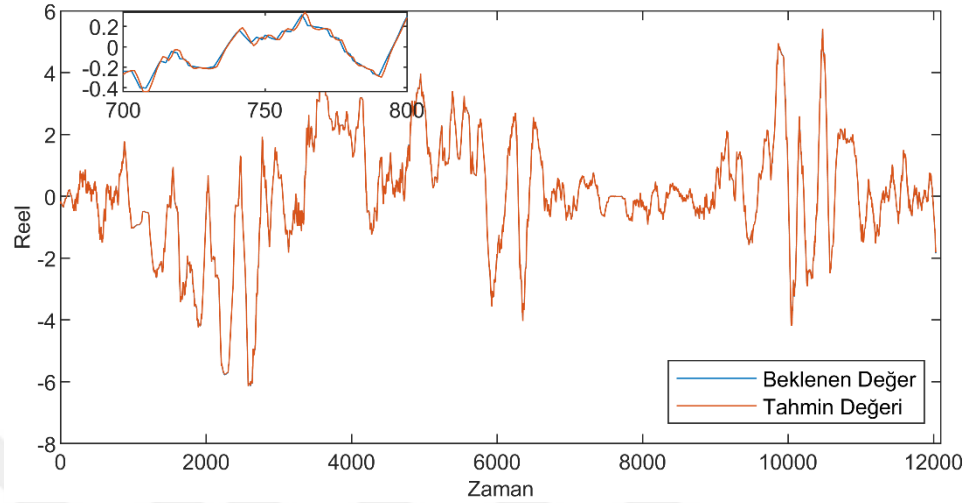


(a)

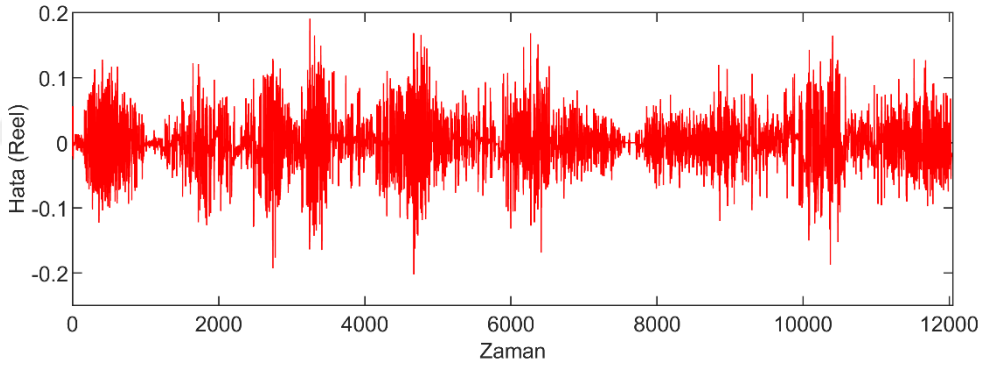


(b)

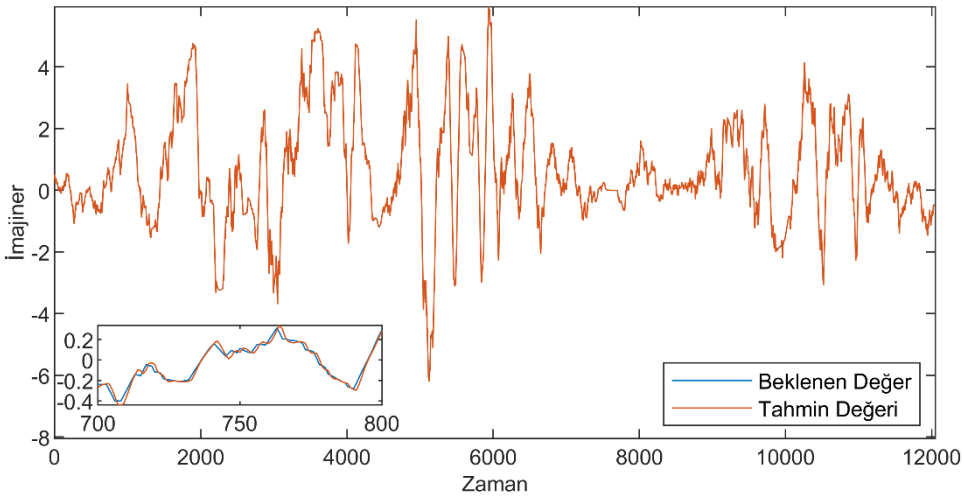


(c)

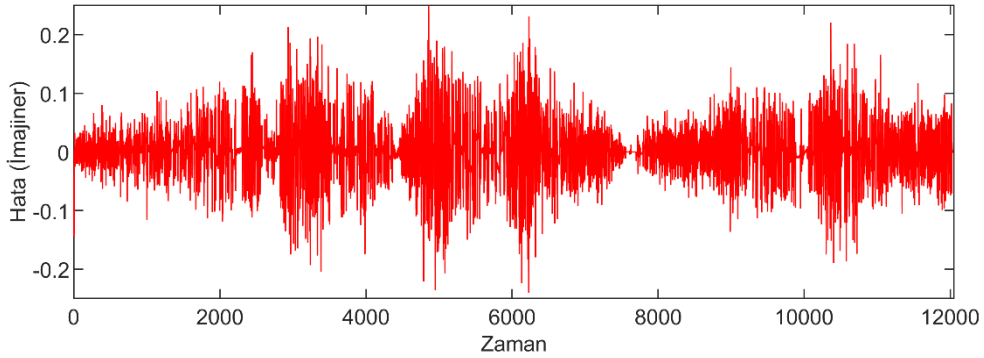


(d)

**Şekil 3.8.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

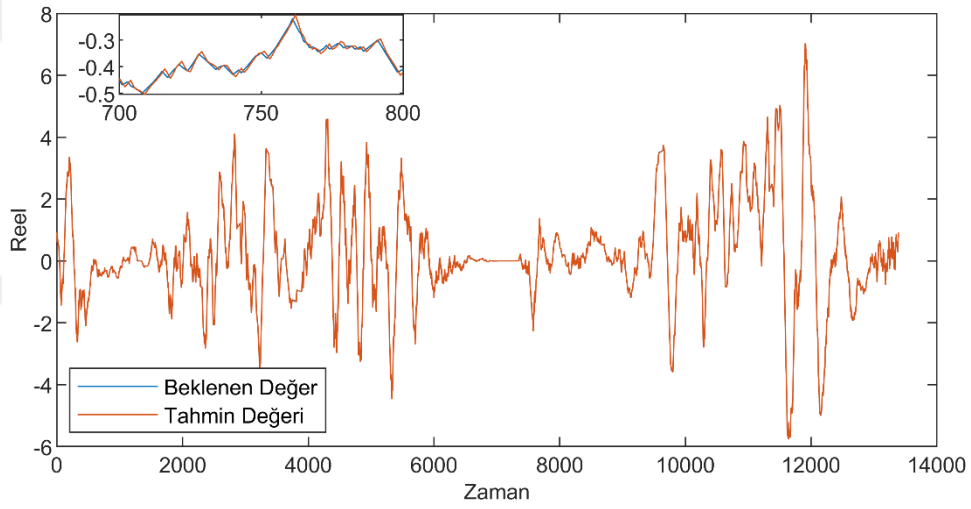


(a)

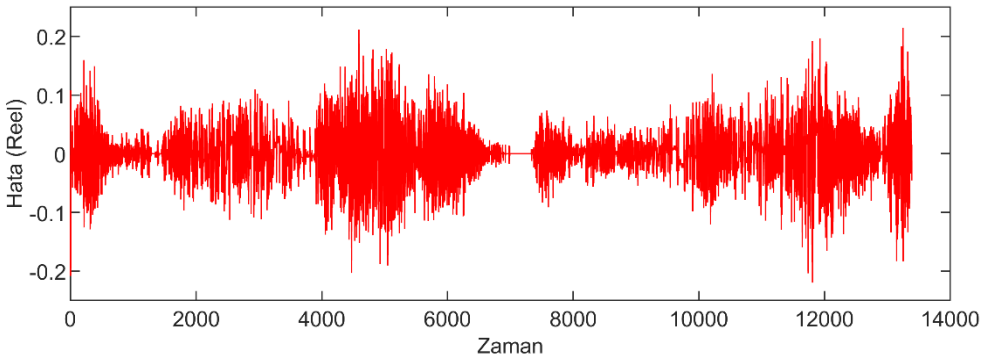


(b)

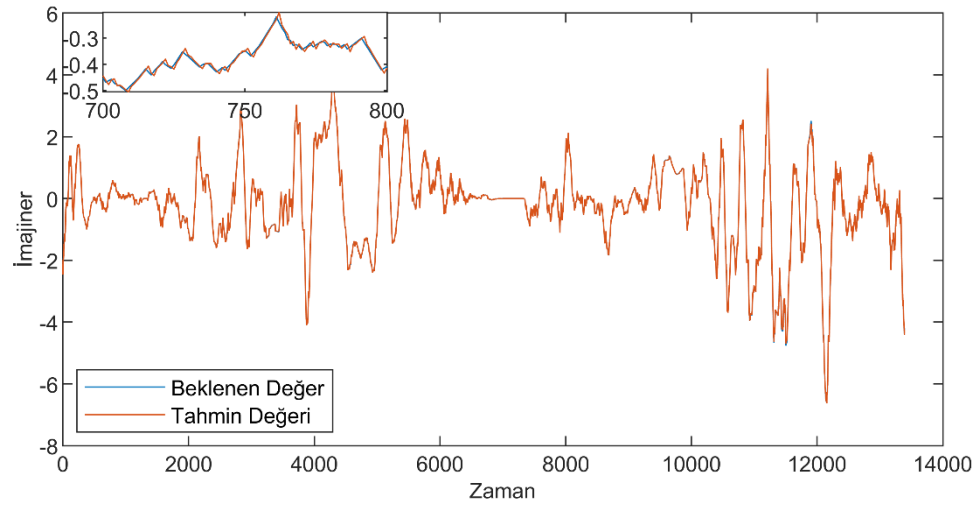


(c)

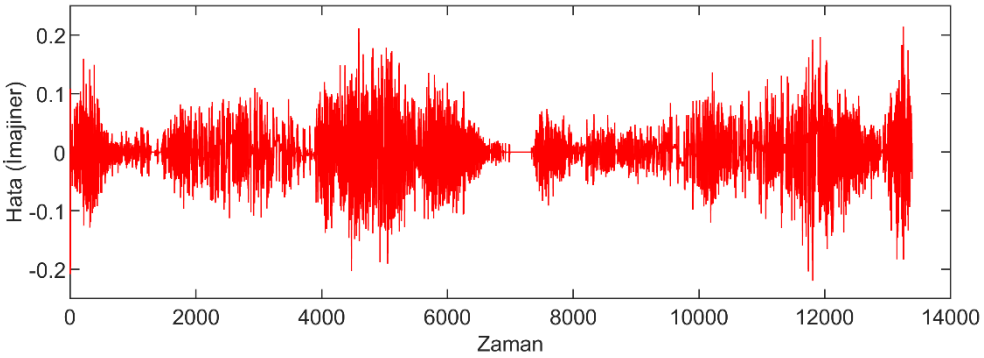


(d)

**Şekil 3.9.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile LSTM modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği*

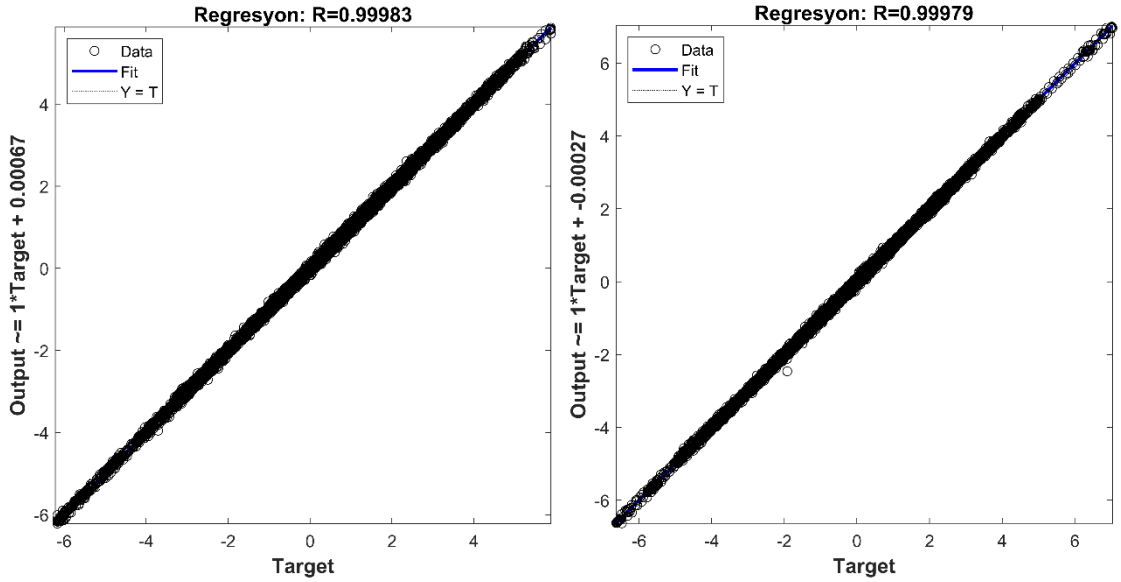


(a) (b)

### 3.7. Çift Yönlü LSTM (BiLSTM) Ağı ile Kompleks-Değerli Rüzgâr Tahmin Performansı

BiLSTM (Bidirectional LSTM), klasik LSTM yapısının hem ileri hem de geri yönde bilgi işleyen çift katmanlı bir versiyonudur. Bu yapı, özellikle gelecek bilginin geçmiş üzerindeki etkisinin önemli olduğu zaman serilerinde daha güçlü sonuçlar üretmektedir. Rüzgâr sinyalleri gibi çevresel veriler hem geçmiş olaylardan hem de gelecek eğilimlerden etkilenebileceği için BiLSTM yapısı bu tür uygulamalarda fayda sağlayabilir. Bu çalışmada BiLSTM modeli kullanılarak yapılan tahminlerin sonuçları Şekil 3.10. ve 3.11.'de gösterilmiştir. Görsellerden modelin sinyalin genel yapısını oldukça başarılı bir şekilde yakaladığı görülmektedir. Ayrıca, Şekil 3.12.'de de VeriSeti1 ve VeriSeti2 üzerinde gerçekleştirilen regresyon analizlerine ait sonuçlarda sunulmuştur.

**Şekil 3.10.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

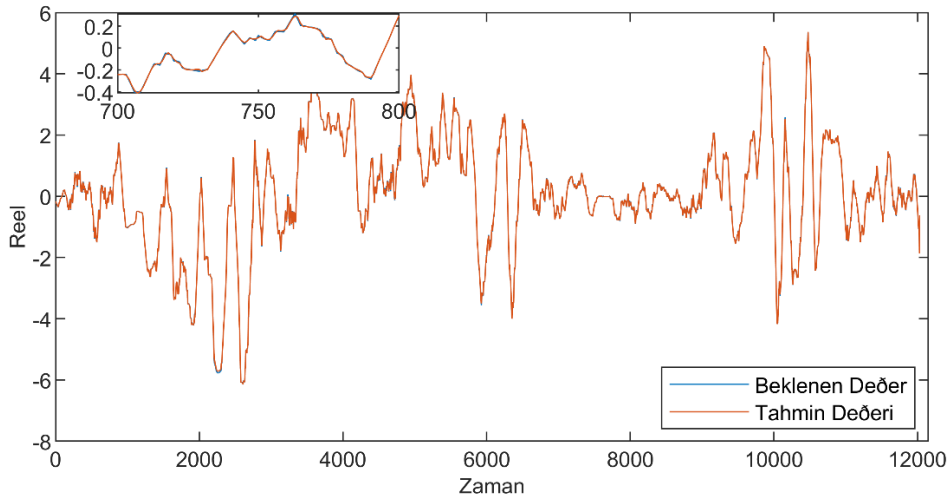


(a)

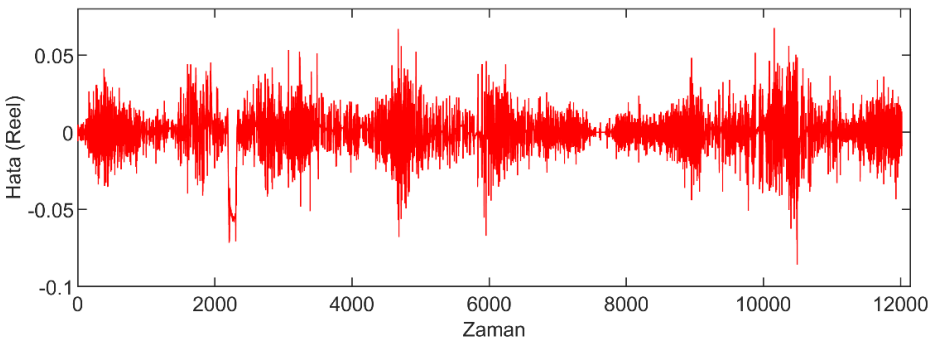


(b)

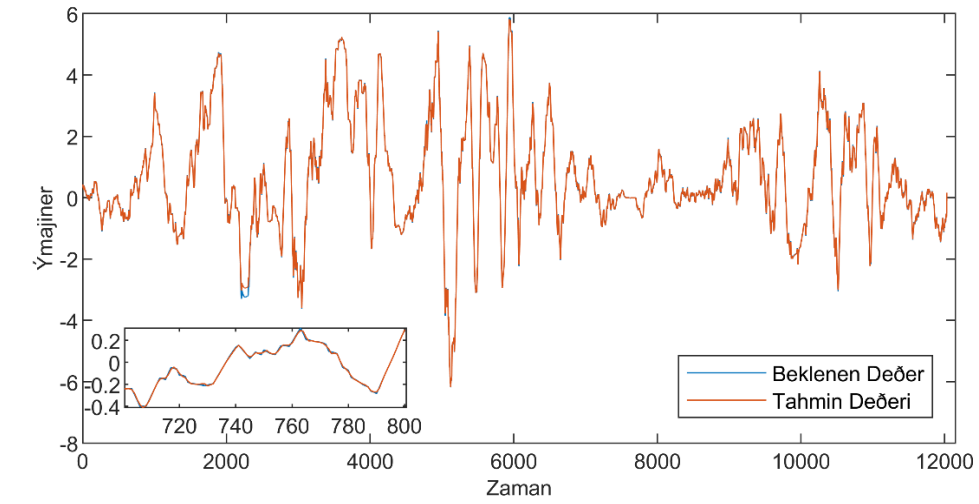


(c)

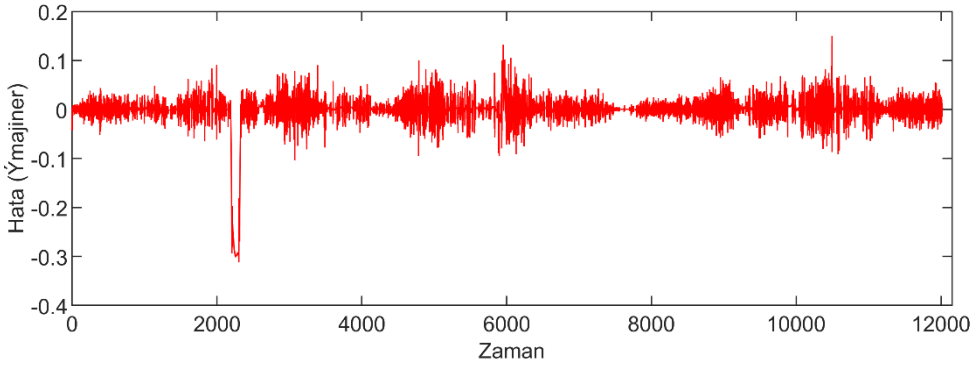


(d)

**Şekil 3.11.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve BiLSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

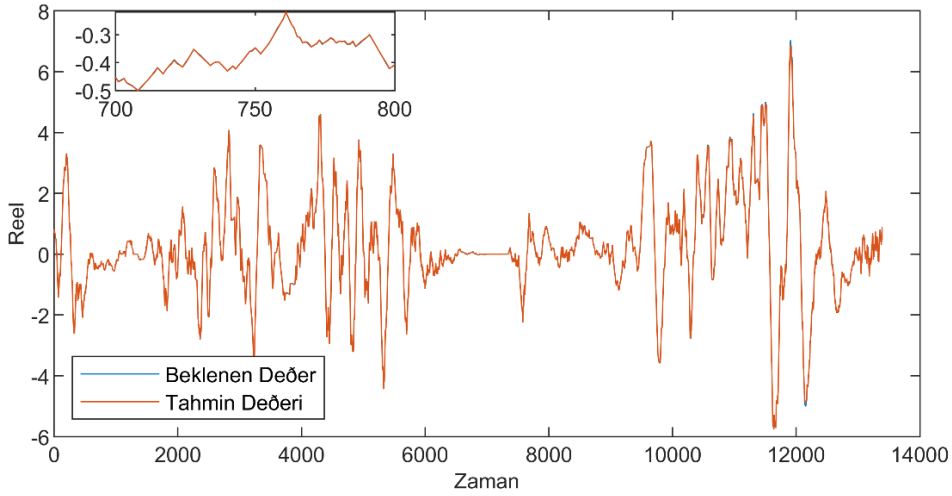


(a)

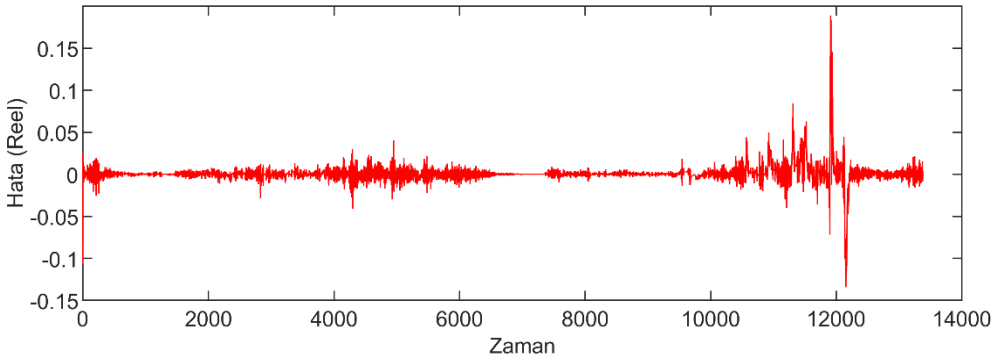
Hata (Reel)
Zaman

(b)

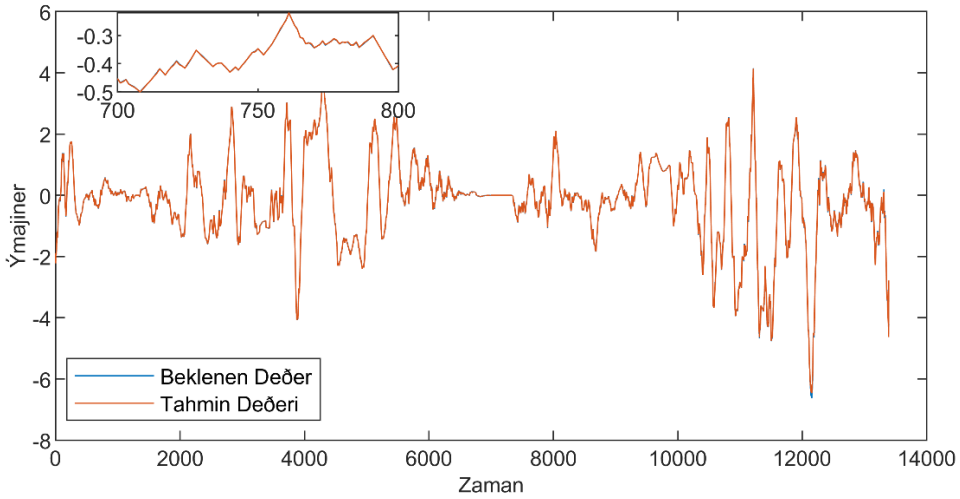
Ýmajiner
Zaman
Beklenen Deðer
Tahmin Deðeri

(c)

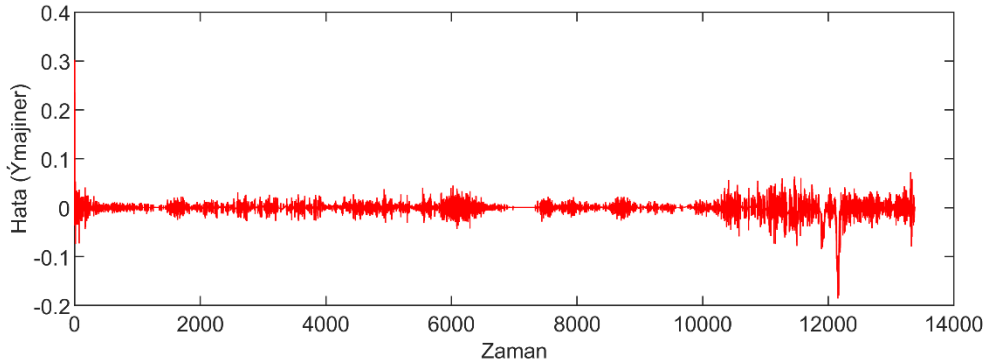
Hata (Ýmajiner)
Zaman

(d)

**Şekil 3.12.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile BiLSTM modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği*

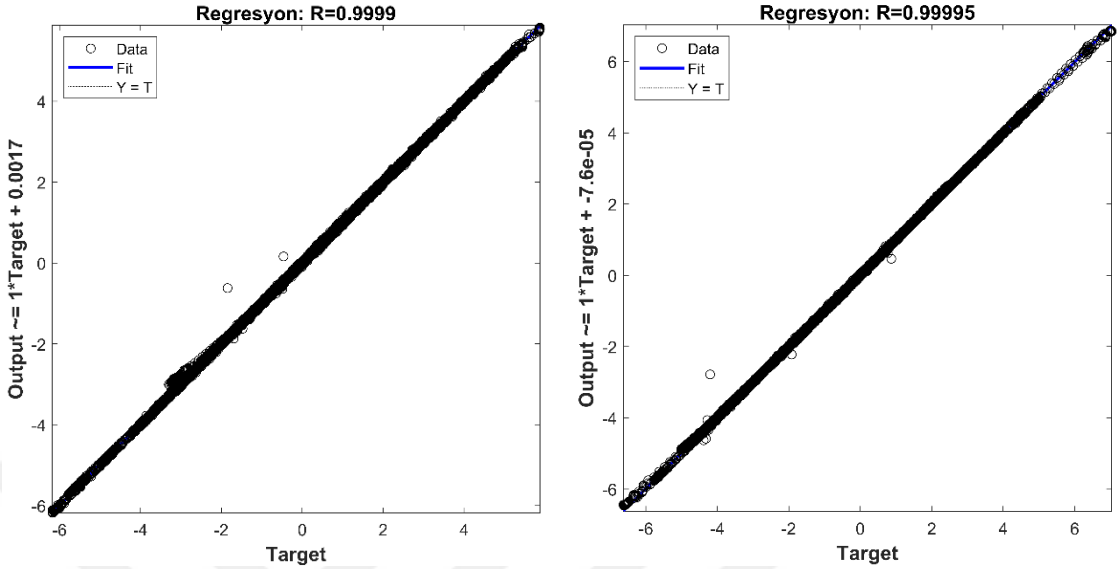


(a) (b)

## 3.8. Kapı Kontrollü Tekrarlayan Birim (GRU) Ağı ile Kompleks-Değerli Rüzgâr Tahmin Performansı

GRU (Gated Recurrent Unit) mimarisi, LSTM'e benzer şekilde zaman serilerindeki uzun vadeli bağımlılıkları modellemek amacıyla geliştirilmiştir. LSTM'e kıyasla daha az sayıda kapı (gate) ve daha sade bir yapı kullanarak hem hafızayı hem de bilgi akışını kontrol eder. Bu nedenle daha az hesaplama kaynağı gerektirmesi ve daha hızlı eğitilmesi ile bilinir. GRU modeli bu çalışmada rüzgâr sinyallerinin tahmini amacıyla uygulanmış; elde edilen sonuçlar Şekil 3.13. ve Şekil 3.14.'te verilmiştir. VeriSeti1 ve VeriSeti2 üzerinde gerçekleştirilen regresyon analizlerine ait sonuçlarda ise Şekil 3.15.'te de sunulmuştur.

**Şekil 3.13.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

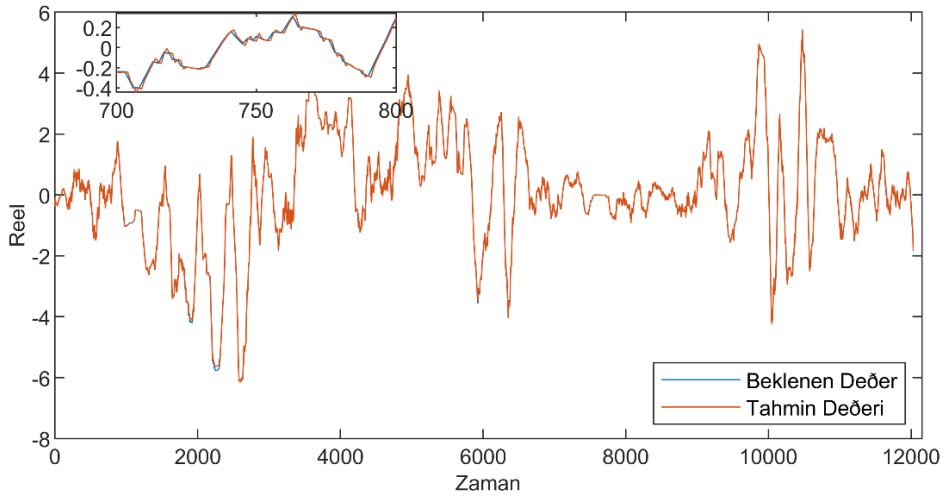


(a)

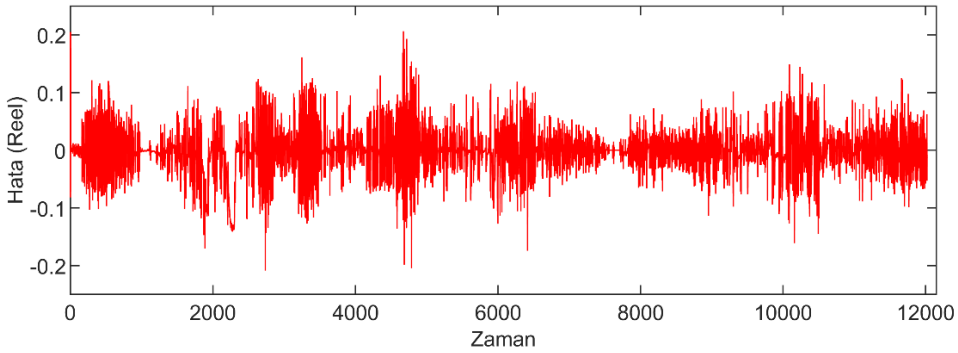


(b)

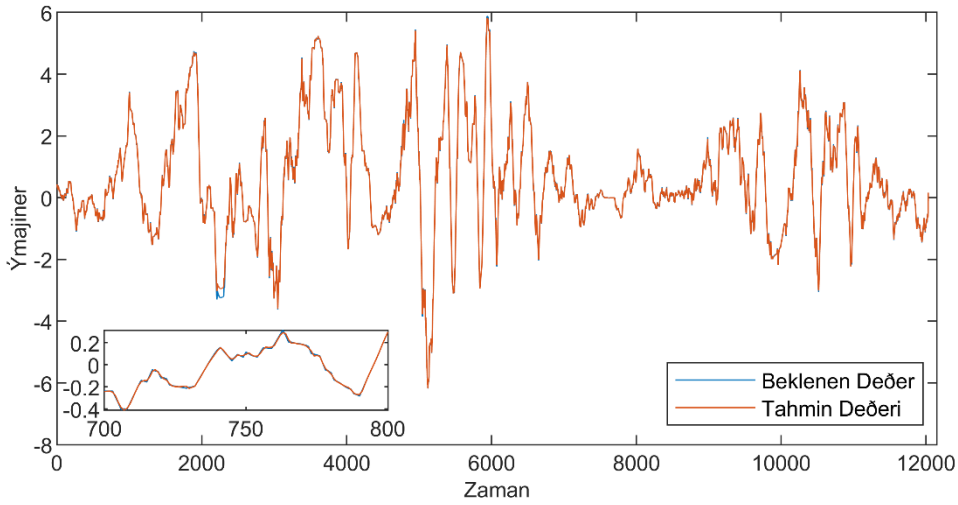


(c)

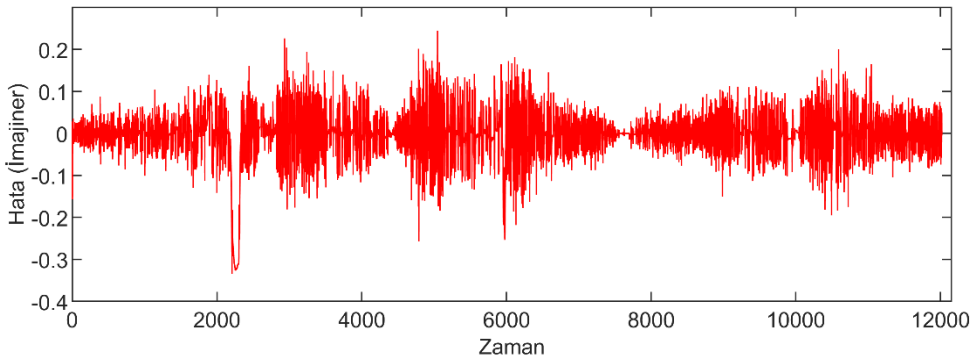


(d)

**Şekil 3.14.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve GRU modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

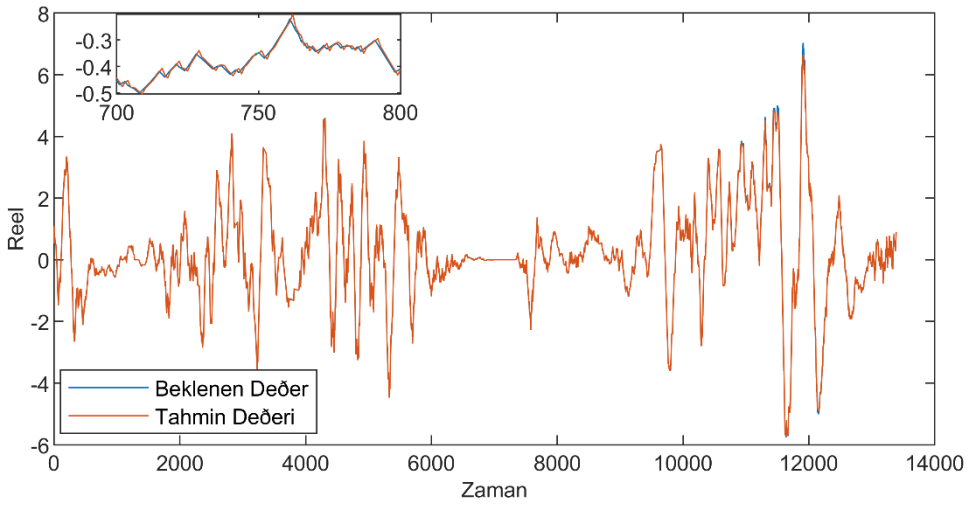


(a)

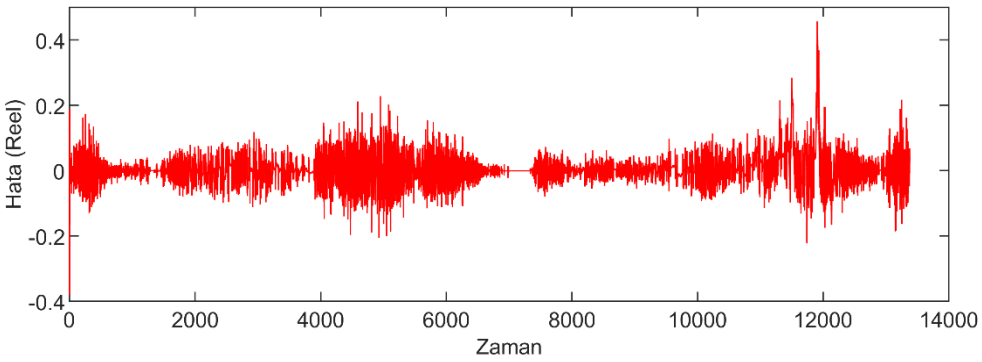


(b)

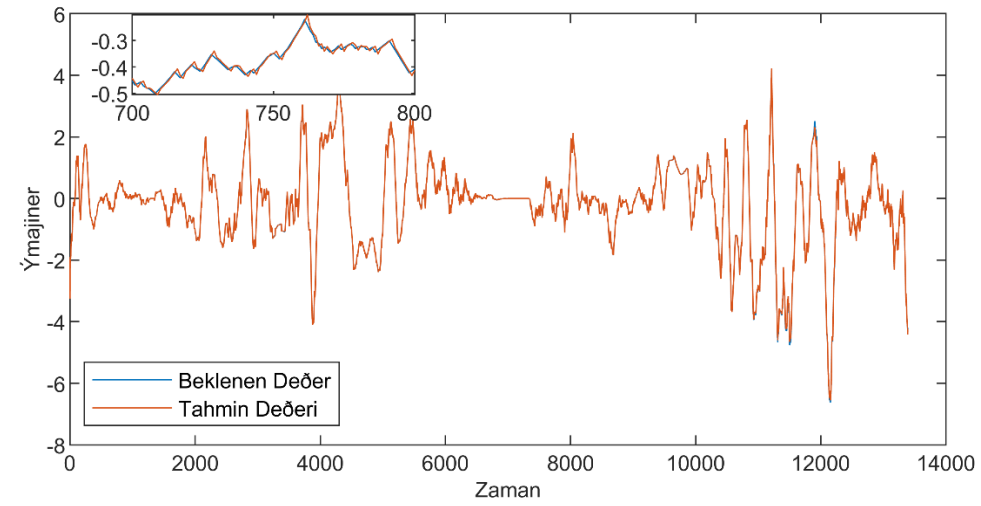


(c)

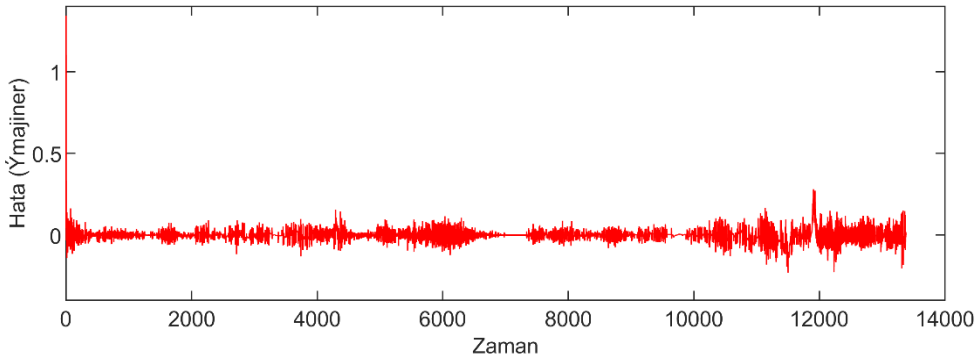


(d)

**Şekil 3.15.** *VeriSeti1(a) ve VeriSeti2'de(b) gerçek değerler ile GRU modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği*

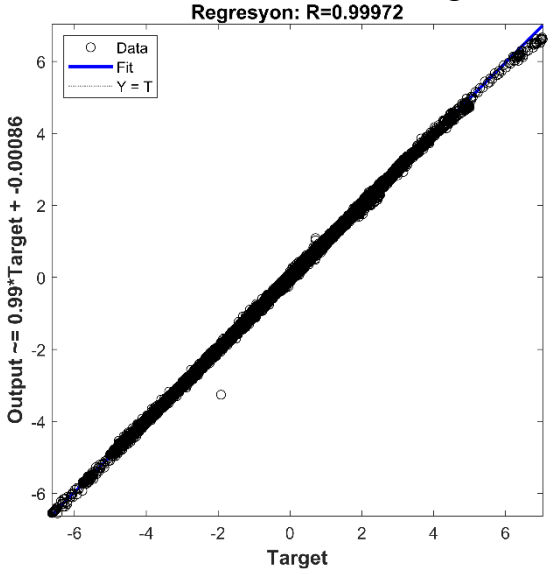


(a)

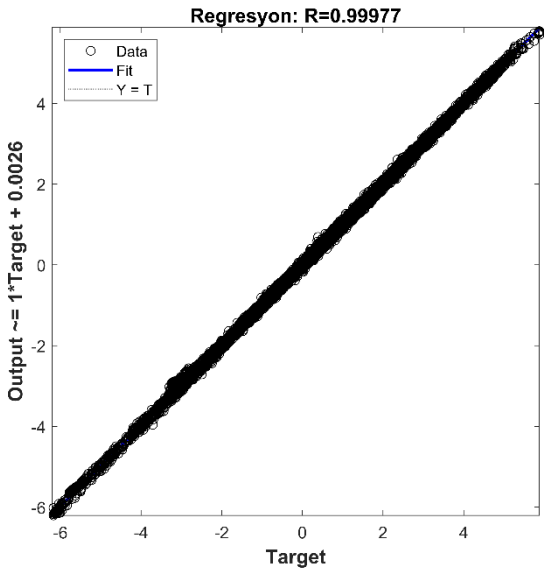


(b)

### 3.9. Tek Boyutlu Konvolüsyonel Sinir Ağı ve LSTM (1D-CNN + LSTM) Hibrit Modeli ile Kompleks-Değerli Rüzgâr Tahmin Performansı

Konvolüsyonel sinir ağları (CNN), girdilerdeki yerel desenleri (örneğin frekans değişimleri, darbe benzeri yapılar) tespit etmekte başarılı iken; LSTM yapıları ise zamansal bağıntıların öğrenilmesinde öne çıkar. 1D-CNN + LSTM hibrit yapısı, bu iki güçlü öğrenme mekanizmasını bir araya getirerek hem yerel örüntüleri hem de uzun vadeli bağıntıları aynı anda öğrenebilmeyi amaçlamaktadır. Bu çalışmada önce 1D konvolüsyonel katmanlar ile öznitelik çıkarımı yapılmış, ardından LSTM katmanları ile zaman serisi içindeki bağıntılar modellenmiştir. Şekil 3.16. ve 3.17.'de sunulan sonuçlara göre model hem reel hem de imajiner bileşenlerde yüksek doğrulukla tahmin gerçekleştirmiştir. VeriSeti1 ve VeriSeti2 üzerinde gerçekleştirilen regresyon analizlerine ait sonuçlarda ise Şekil 3.18.'de de sunulmuştur.

**Şekil 3.16.** *VeriSeti1 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

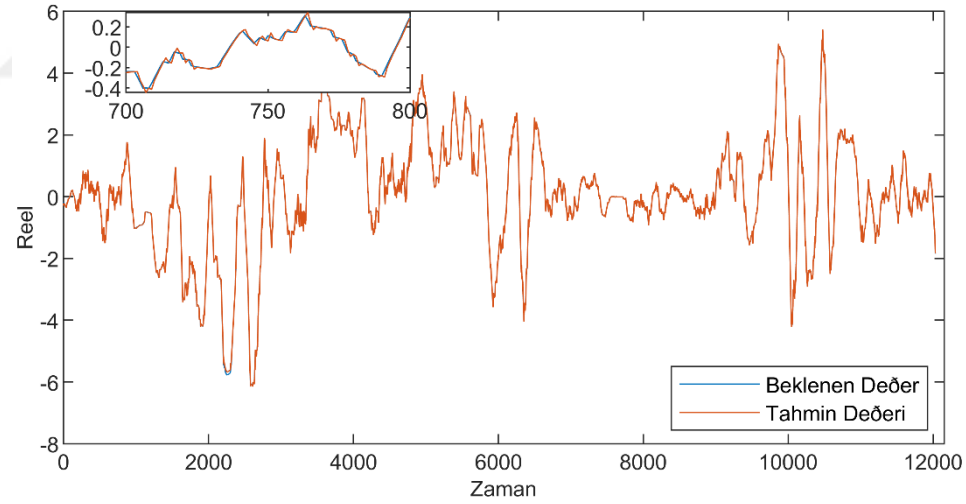


(a)

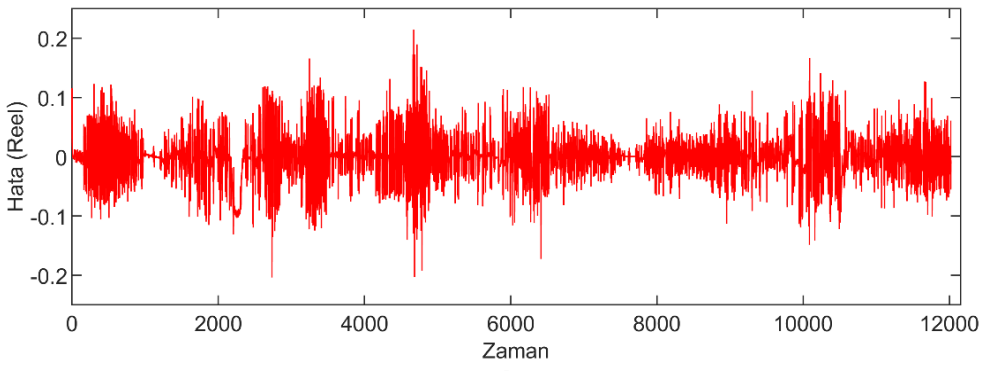


(b)

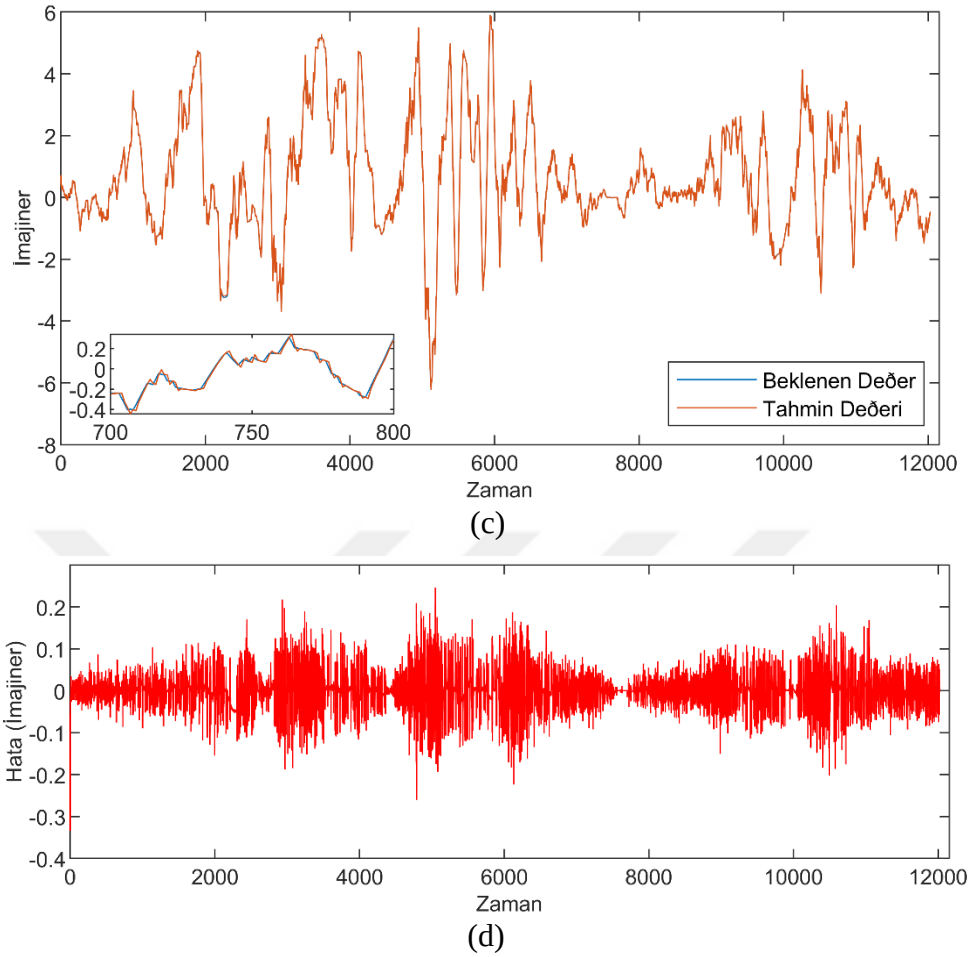


**Şekil 3.17.** *VeriSeti2 üzerinde gerçekleştirilen benzetim sonuçları. (a) reel eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerlerler, (b) reel eksendeki hatalar, (c) imajiner eksende beklenen değerler ve 1D-CNN + LSTM modeli kullanılarak tahmin edilen değerler, (d) imajiner eksendeki hatalar*

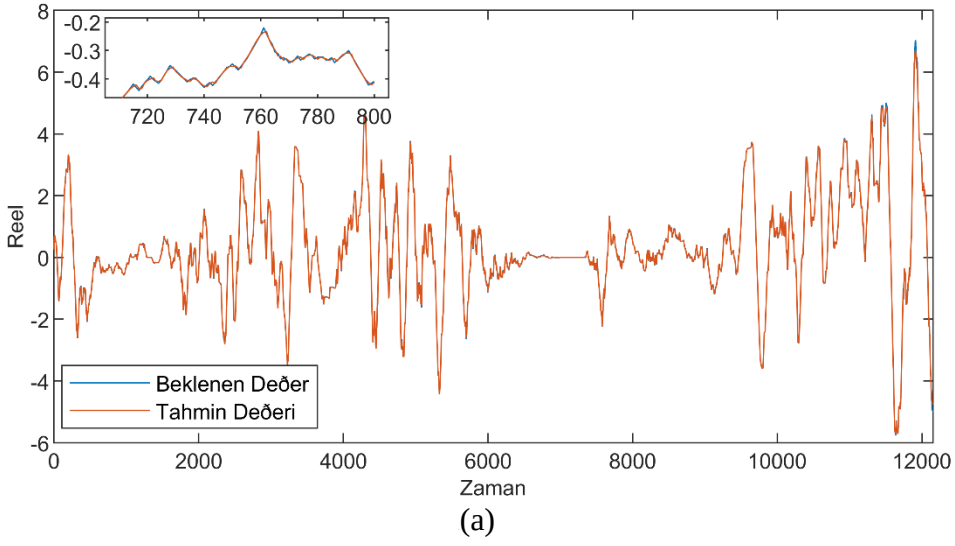

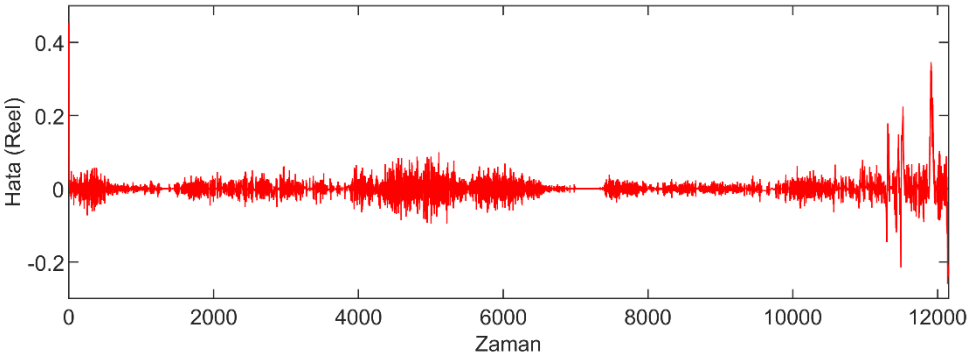
Hata (Reel)
0.4
0.2
0
-0.2
0
2000
4000
6000
8000
10000
12000
Zaman

(b)

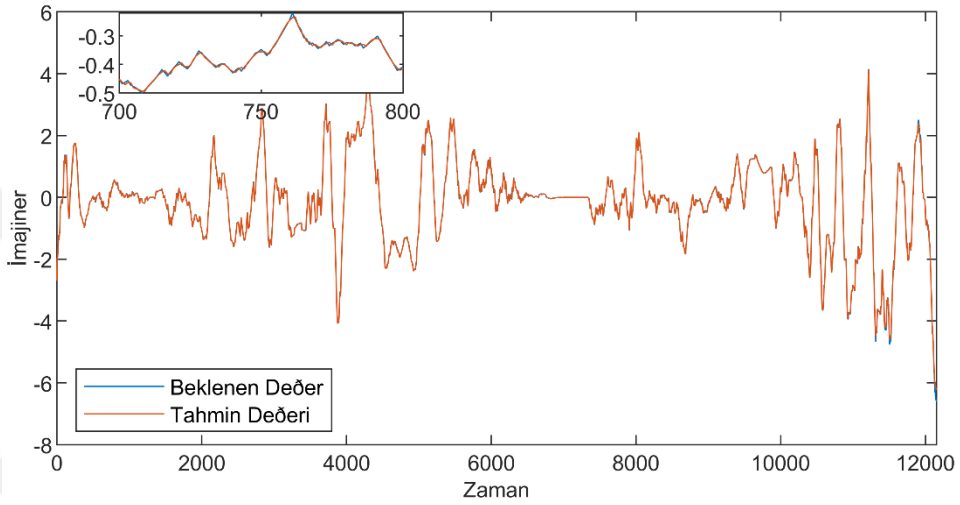
İmajiner
6
4
2
0
-2
-4
-6
-8
-0.3
-0.4
-0.5
700
750
800
Beklenen Değer
Tahmin Değeri
0
2000
4000
6000
8000
10000
12000
Zaman

(c)

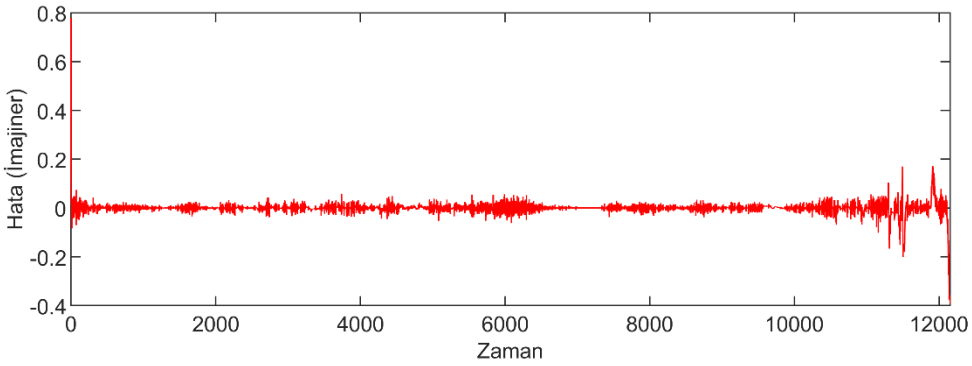
Hata (İmajiner)
0.8
0.6
0.4
0.2
0
-0.2
-0.4
0
2000
4000
6000
8000
10000
12000
Zaman

(d)

**Şekil 3.18.** *VeriSeti1(a) ve VeriSeti2'de (b) gerçek değerler ile 1D-CNN + LSTM modeli tarafından tahmin edilen değerler arasındaki regresyon grafiği*

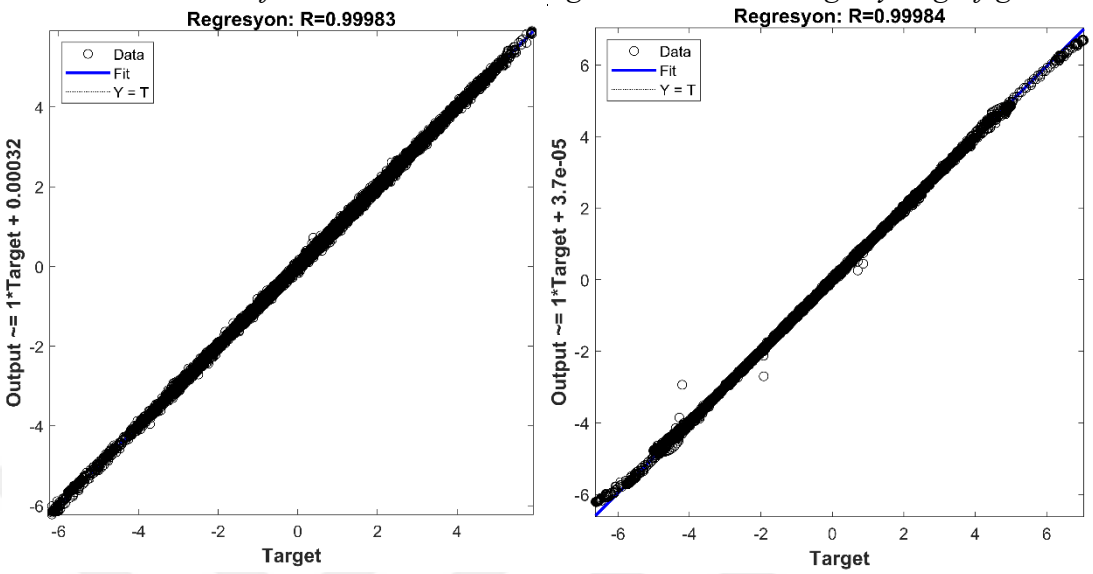


(a) (b)

# DÖRDÜNCÜ BÖLÜM

# SONUÇ

Bu tez çalışmasında, rüzgâr hızı ve yönü gibi yönlü meteorolojik büyüklüklerin kısa vadeli tahmini amacıyla kompleks-değerli sinyal temsiline dayalı yeni bir yaklaşım önerilmiş ve bu yapının farklı derin öğrenme modelleriyle tahmin başarımı detaylı biçimde değerlendirilmiştir. Literatürde çoğunlukla ayrı ayrı ele alınan hız ve yön bileşenleri, bu çalışmada genlik ve faz bilgisiyle birlikte kompleks düzlemde bütüncül olarak temsil edilmiştir. Böylece hem sinyalin fiziksel doğasına daha uygun bir modelleme yapılmış hem de veri boyutunda sadeleştirme sağlanarak öğrenme sürecinin bilgi yoğunluğu artırılmıştır.

Bu amaçla, altı farklı derin öğrenme mimarisi (MLP, 1D-CNN, LSTM, BiLSTM, GRU ve 1D-CNN + LSTM) oluşturulmuş ve 2010 yılına ait Şubat ve Aralık aylarını temsil eden iki farklı veri kümesi kullanılarak modellenmiştir. Tahmin performansı; standart tahmin kazancı, korelasyon katsayısı ve eğitim kayıp değerleri gibi metriklerle değerlendirilmiştir. Elde edilen bulgulara göre, BiLSTM modeli her iki veri kümesinde de en yüksek standart tahmin kazancı ve en düşük hata değerlerine ulaşarak en başarılı yapı olmuştur. Bu başarı, çift yönlü bilgi akışına dayalı zaman serisi modellemenin kompleks-veri yapısıyla birleştiğinde tahmin gücünü önemli ölçüde artırdığını göstermektedir. LSTM modeli, BiLSTM'e benzer doğruluk oranları sunmakla birlikte, eğitim süresi açısından en uzun model olarak dikkat çekmiştir. 1D-CNN, düşük eğitim süresi ve hesaplama maliyeti ile öne çıkmış, tahmin doğruluğu açısından rekabetçi sonuçlar üretmiştir. Özellikle gerçek zamanlı uygulamalar açısından verimli bir yapı sunmaktadır.

1D-CNN + LSTM hibrit modeli, yön tahmininde hem konvolüsyonel hem de zamansal ilişkileri birlikte öğrenerek dengeli ve güvenilir bir performans göstermiştir. GRU, LSTM'e benzer doğruluk düzeylerine ulaşmasına rağmen daha sade yapısıyla eğitim verimliliği sunmuştur. Öte yandan, MLP modeli en kısa eğitim süresine sahip olmasına karşın, kompleks sinyaldeki örüntüleri yakalamakta yetersiz kalmış ve en düşük doğruluk değerleriyle sınırlı bir başarı göstermiştir.

Bu bulgular, kompleks-değerli sinyal yaklaşımı ile derin öğrenme temelli rüzgâr tahmini sistemlerinin, klasik reel veriye dayalı yöntemlere kıyasla daha yüksek doğruluk, daha düşük hata ve daha güçlü genelleme başarımı sunduğunu ortaya koymaktadır. Ayrıca, bu yapıların gerçek dünyadaki mikro-şebeke yönetimi, rüzgâr türbini kontrolü, kısa vadeli enerji üretim planlaması gibi uygulamalarda karar destek sistemi olarak kullanılabilecek düzeyde olduğu değerlendirilmiştir.

Bu çalışmanın özgün katkısı, rüzgâr hızı ve yönünü kompleks düzlemde entegre şekilde modelleyen ve bu temsili derin öğrenme ile harmanlayan bir yapı sunmasıdır. Literatürde bu boyutta bütüncül yaklaşımlar oldukça sınırlı sayıda yer almaktadır. Sunulan sonuçlar, bu temsilin güçlü öngörü kabiliyeti sağladığını açık biçimde göstermiştir.

Gelecekteki çalışmaların, bu modellerin farklı coğrafi bölgelerden elde edilen büyük ölçekli veri kümeleriyle test edilmesi, genellenebilirliği artırmak açısından önem arz etmektedir. Ayrıca, zaman serisi tahminine özel geliştirilmiş dikkat mekanizmalı derin öğrenme yapıları ile kompleks verinin birlikte değerlendirilmesi hem tahmin başarımını hem de model yorumlanabilirliğini daha üst seviyelere taşıyabilir. Bu bağlamda, kompleks sinyallerin yapay zekâ ile modellenmesine yönelik bu çalışma, literatürdeki boşluğu dolduracak nitelikte önemli bir adım olarak değerlendirilmektedir.

# KAYNAKÇA


Alexiadis, M. C., Dokopoulos, P. S., Sahsamanoglou, H. S., & Manousaridis, I. M. (1998). Short-term forecasting of wind speed and related electrical power. *Solar Energy*, *63*(1), 61–68. https://doi.org/10.1016/S0038-092X(98)00032-2

American Wind Energy Association. (2020). *Wind powers America: Third quarter 2020 market report*. American Clean Power Association. https://cleanpower.org/wp-content/uploads/2021/02/WPA_2020Q3_Public_Version.pdf (Erişim tarihi: 01 Şubat 2025)

Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. ArXiv Preprint ArXiv:1409.0473 https://doi.org/10.48550/arXiv.1409.0473.

Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, *2*(1), 1–127. https://doi.org/10.1561/2200000006

Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, *5*(2), 157–166. https://doi.org/10.1109/72.279181

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (1994). *Time series analysis, forecasting and control*. Prentice Hall.

Brown, B. G., Katz, R. W., & Murphy, A. H. (1984). Time series models to simulate and forecast wind speed and power. *Journal of Climate and Applied Meteorology*, *23*(11), 1184–1195. https://doi.org/10.1175/1520-0450(1984)023%3C1184:TSMTSA%3E2.0.CO;2

Cadenas, E., Rivera, W., Campos-Amezcua, R., & Heard, C. (2016). Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model. *Energies*, *9*(2), 109. https://doi.org/10.3390/en9020109

Chang, W. Y., Liu, C. C., & Lo, K. W. (2014). A literature review of wind forecasting methods. *Journal of Power and Energy Engineering*, *2*(4), 161–168. https://doi.org/10.4236/jpee.2014.24023

Chen, X., Liu, J., Jiang, T., Xu, Y., & Wang, Y. (2022). A novel loss function of deep learning for wind speed prediction. *Energy, 238*, 121808. https://doi.org/10.1016/j.energy.2021.121808

Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation [Preprint]. *arXiv*. https://doi.org/10.48550/arXiv.1406.1078

Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling [Preprint]. arXiv. https://doi.org/10.48550/arXiv.1412.3555

Duyar, Y., Emlek, A., & Mengüç, E. C. (2023). Kompleks Değerli Veriler Kullanılarak Derin Öğrenme Yöntemleri ile Rüzgar Hızı ve Yönü Tahmini. *5. Uluslararası Türk Dünyası Fen Bilimleri ve Mühendislik Kongresi (TURK-COSE 2023)*, Bişkek, Kırgızistan, 1–4.

Ehsan, M. A., Ali, S., Rauf, A., Khan, H. U., & Arif, M. (2020). Wind Speed Prediction and Visualization Using Long Short-Term Memory Networks (LSTM). *ArXiv Preprint ArXiv:2005.12401*. https://doi.org/10.48550/arXiv.2005.12401

Erdem, E., & Shi, J. (2011). ARMA Based Approaches for Forecasting the Tuple of Wind Speed and Direction. *Applied Energy*, *88*(4), 1405–1414. https://doi.org/10.1016/j.apenergy.2010.10.031

Felbo, B., Mislove, A., Søgaard, A., Rahwan, I., & Lehmann, S. (2017). Using millions of emoji occurrences to learn any-domain representations for detecting sentiment, emotion and sarcasm. *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (pp. 1616–1625). Association for Computational Linguistics. https://doi.org/10.18653/v1/D17-1169

Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M., & Draxl, C. (2011). *The State-Of-The-Art in Short-Term Prediction of Wind Power: A Literature Overview*, 2nd edition. ANEMOS.plus. https://doi.org/10.11581/DTU:00000017

Global Wind Energy Council. (2022). *Global wind report 2022*. Global Wind Energy Council. https://www.gwec.net/reports/globalwindreport/2022 (Erişim tarihi: 10 Aralık 2024)

Goh, S. L., Popović, D. H., & Mandic, D. P. (2004). Complex-valued estimation of wind profile and wind power. *Proceedings of the 12th IEEE Mediterranean Electrotechnical Conference (MELECON 2004)* (Vol. 3, pp. 1037–1040). IEEE. https://doi.org/10.1109/MELCON.2004.1348231

Goh, S. L., Chen, M., Popović, D. H., Aihara, K., Obradović, D., & Mandic, D. P. (2006). Complex-valued forecasting of wind profile. *Renewable Energy, 31(11),* 1733–1750. https://doi.org/10.1016/j.renene.2005.07.006

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Graves, A. (2012). *Supervised sequence labelling with recurrent neural networks* (Vol. 385). Springer.

Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM networks. *Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN)* (Vol. 4, pp. 2047–2052). IEEE. https://doi.org/10.1109/IJCNN.2005.1556215

Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems, 28*(10), 2222–2232. https://doi.org/10.1109/TNNLS.2016.2582924

Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.

He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (pp. 1026–1034). IEEE. https://doi.org/10.1109/ICCV.2015.123

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation, 9*(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735

Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks, 4*(2), 251–257. https://doi.org/10.1016/0893-6080(91)90009-T

Hu, Q., Zhang, R., & Zhou, Y. (2016). Transfer learning for short-term wind speed prediction with deep neural networks. *Renewable Energy, 85*, 83–95. https://doi.org/10.1016/j.renene.2015.06.034

International Renewable Energy Agency. (2022). *Renewable power generation costs in 2021*. International Renewable Energy Agency. https://www.irena.org/Publications/2022/Jul/Renewable-Power-Generation-Costs-in-2021 (Erişim tarihi: 10 Aralık 2024)

Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*. https://doi.org/10.48550/arXiv.1412.6980

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (Vol. 25, pp. 1097–1105).

Lalarukh, K., & Yasmin, Z. (1997). Time series models to simulate and forecast hourly averaged wind speed in Quetta, Pakistan. *Solar Energy*, *61*(1), 23–32. https://doi.org/10.1016/S0038-092X(97)00037-6

Landberg, L. (2001). Short-term prediction of local wind conditions. *Journal of Wind Engineering and Industrial Aerodynamics*, *89*(3–4), 235–245. https://doi.org/10.1016/S0167-6105(00)00079-9

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*, 436–444. https://doi.org/10.1038/nature14539

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, *86*(11), 2278–2324. https://doi.org/10.1109/5.726791

Li, G., & Shi, J. (2010). On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, *87*(7), 2313–2320. https://doi.org/10.1016/j.apenergy.2009.12.013

Li, Y., Wang, J., Gao, S., & Wu, L. (2018). A two-stage approach for combined heat and power economic emission dispatch: Integrating multi-objective optimization with decision making. *Energy*, *162*, 237–254. https://doi.org/10.1016/j.energy.2018.07.200

Li, Y., Xu, H., Wang, Y., Li, M., & Li, Y. (2022). Privacy-preserving spatial–temporal scenario generation of renewable energies: A federated deep generative learning

approach. *IEEE Transactions on Industrial Informatics*, *18*(4), 2310–2320. https://doi.org/10.1109/TII.2021.3098259

Liu, H., Mi, X., Li, Y., Liu, Z., & Yang, Y. (2018). Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM. *Energy Conversion and Management*, *159*, 54–64. https://doi.org/10.1016/j.enconman.2018.01.010

Long, H., Li, D., Wang, K., Liu, Q., & Wang, F. (2022). Research on short-term wind speed prediction based on deep learning model under the scenario of multi-fan distributed generation. *Energy Reports*, *8*, 14183–14199. https://doi.org/10.1016/j.egyr.2022.10.399

Mabel, M. C., & Fernandez, E. (2008). Analysis of wind power generation and prediction using ANN: a case study. *Renewable Energy*, *33*(5), 986–992. https://doi.org/10.1016/j.renene.2007.06.013

Mandic, D. P., Javidi, S., & Goh, S. L. (2009). Complex-valued prediction of wind profile using augmented complex statistics. *Renewable Energy*, 34(1), 196–201. https://doi.org/10.1016/j.renene.2008.03.022

Mandic, D. P., & Goh, S. L. (2009). *Complex valued nonlinear adaptive filters: Noncircularity, widely linear and neural models*. Wiley.

Marugán, A. P., Márquez, F. P. G., Pérez, J. M. P., & Ruiz-Hernández, D. (2018). A survey of artificial neural network in wind energy systems. *Applied Energy*, *228*, 1822–1836. https://doi.org/10.1016/j.apenergy.2018.07.084

Mengüç, E. C., & Acır, N. (2018). An augmented complex-valued least-mean kurtosis algorithm for the filtering of noncircular signals. *IEEE Transactions on Signal Processing*, *66*(2), 438–448. https://doi.org/10.1109/TSP.2017.2768024

Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. In J. Fürnkranz & T. Joachims (Eds.), *Proceedings of the 27th International Conference on Machine Learning (ICML-10)* (pp. 807–814). Omnipress.

Nielsen, H. A., Madsen, H., & Nielsen, T. S. (2006). Using Quantile Regression to Extend an Existing Wind Power Forecasting System with Probabilistic Forecasts. *Wind Energy*, *9*(1–2), 95–108. https://doi.org/10.1002/we.180

Ruder, S. (2016). An overview of gradient descent optimization algorithms. *ArXiv Preprint ArXiv:1609.04747*. https://doi.org/10.48550/arXiv.1609.04747

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, *61*, 85–117. https://doi.org/10.1016/j.neunet.2014.09.003

Shukur, O. B., & Lee, M. H. (2015). Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA. *Renewable Energy*, *76*, 637–647. https://doi.org/10.1016/j.renene.2014.11.084

Smith, R., & Tanaka, J. (2012). Limitations of FIR and IIR filters in nonlinear wind signal processing. *Proceedings of the International Conference on Environmental Data Analysis*, 57–64.

Soman, S. S., Zareipour, H., Malik, O., & Mandal, P. (2010). A Review of Wind Power and Wind Speed Forecasting Methods with Different Time Horizons. *2010 North American Power Symposium*, 1–8. https://doi.org/10.1109/NAPS.2010.5619586

Torres, J. L., García, A. M., De Blas, M., & De Francisco, A. (2005). Forecast of hourly average wind speed with ARMA models in Navarre. *Solar Energy*, *79*(1), 65–77. https://doi.org/10.1016/j.solener.2004.09.013

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems* (Vol. 30, pp. 5998–6008). Curran Associates, Inc. [Preprint]. arXiv. https://doi.org/10.48550/arXiv.1706.03762

Wang, J., Qin, Y., Li, Y., & Ding, Y. (2016). Analysis and application of forecasting models in wind power integration: A review of multi-step-ahead wind speed forecasting models. *Renewable and Sustainable Energy Reviews*, *60*, 960–981. https://doi.org/10.1016/j.rser.2016.01.114

Wang, L., Yu, M., Du, X., Wang, C., & Xu, H. (2022). Wind speed prediction using measurements from neighboring locations and combining AdaBoost algorithm

with extreme learning machine. *Energy Reports*, *8*, 1508–1518. https://doi.org/10.1016/j.egyr.2021.12.062

WindEurope. (2022). *Offshore wind in Europe: Key trends and statistics 2021*. WindEurope. https://windeurope.org (Erişim tarihi: 18 Aralık 2024)

World Health Organization. (2023). *Air pollution*. World Health Organization. https://www.who.int/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health (Erişim tarihi: 14 Aralık 2024)

Wu, Z., Lv, Y., Su, H., Xu, Y., & Wang, Y. (2022). A comprehensive review of deep learning approaches in wind forecasting applications. *CAAI Transactions on Intelligence Technology*, *7*(2), 129–143. https://doi.org/10.1049/cit2.12076

Yu, C., Li, J., Zhang, D., & Wang, C. (2018). A novel framework for wind speed prediction based on recurrent neural networks and support vector machine. *Energy Conversion and Management*, *178*, 137–145. https://doi.org/10.1016/j.enconman.2018.10.008

Zhang, W., Chen, H., Li, K., & Jin, L. (2020). Hybrid system based on a multi-objective optimization and kernel approximation for multi-scale wind speed forecasting. *Applied Energy*, *277*, 115561. https://doi.org/10.1016/j.apenergy.2020.115561

Zhou, Q., Wang, C., & Zhang, G. (2019). Hybrid forecasting system based on an optimal model selection strategy for different wind speed forecasting problems. *Applied Energy*, *250*, 1559–1580. https://doi.org/10.1016/j.apenergy.2019.05.016

# TEZ İNTİHAL RAPORU

KOMPLEKS-DEĞERLİ VERİLER KULLANILARAK DERİN ÖĞRENME YÖNTEMLERİ İLE RÜZGAR HIZI VE YÖNÜ TAHMİNİ

ORİJİNALLİK RAPORU

| %6 | %5 | %4 | %3 |
|---|---|---|---|
| BENZERLİK ENDEKSİ | İNTERNET KAYNAKLARI | YAYINLAR | ÖĞRENCİ ÖDEVLERİ |

BİRİNCİL KAYNAKLAR

| | | |
|---|---|---|
| 1 | Submitted to Dumlupinar University<br>Öğrenci Ödevi | <%1 |
| 2 | 2793ed39-269b-4a6e-bfbb-1dd53eb9ddcb.filesusr.com<br>İnternet Kaynağı | <%1 |
| 3 | polen.itu.edu.tr<br>İnternet Kaynağı | <%1 |
| 4 | Submitted to Heriot-Watt University<br>Öğrenci Ödevi | <%1 |
| 5 | Bayazıt, Esra Calik. "Android Sistemlerde Derin öğrenme tabanlı kötü amaçlı yazılım Tespit Sistemi", Marmara Universitesi (Turkey), 2023<br>Yayın | <%1 |
| 6 | Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK)<br>Öğrenci Ödevi | <%1 |
| 7 | Yılmaz, Ümit. "Makine Öğrenme Algoritmaları Kullanılarak Toplam Ekipman Etkinliği Ölçütünün Tahmin Edilmesi", Balikesir University (Turkey), 2024<br>Yayın | <%1 |
| 8 | acikerisim.ohu.edu.tr<br>İnternet Kaynağı | <%1 |
| 9 | Submitted to Beykent Universitesi<br>Öğrenci Ödevi | <%1 |

| | | |
|---|---|---|
| 10 | dspace.gazi.edu.tr<br>İnternet Kaynağı | <%1 |
| 11 | turk-cose.ohu.edu.tr<br>İnternet Kaynağı | <%1 |
| 12 | Submitted to Saglik Bilimleri Universitesi<br>Öğrenci Ödevi | <%1 |
| 13 | acikerisim.karabuk.edu.tr:8080<br>İnternet Kaynağı | <%1 |
| 14 | www.gecekitapligi.com<br>İnternet Kaynağı | <%1 |
| 15 | Çetintaş, Aydın Ozan. "Sivas Iline Ait Meteorolojik Parametrelerin Arıma ve Lstm Yöntemleri Kullanılarak Modellenmesi ve Tahmini", Ankara Universitesi (Turkey), 2024<br>Yayın | <%1 |
| 16 | Submitted to Kocaeli Üniversitesi<br>Öğrenci Ödevi | <%1 |
| 17 | www.eleco.org.tr<br>İnternet Kaynağı | <%1 |
| 18 | Submitted to Abant İzzet Baysal Universitesi<br>Öğrenci Ödevi | <%1 |
| 19 | Submitted to Erciyes Ãniversitesi<br>Öğrenci Ödevi | <%1 |
| 20 | Submitted to Fırat Üniversitesi<br>Öğrenci Ödevi | <%1 |
| 21 | Submitted to Tobb University of Economics & Technology<br>Öğrenci Ödevi | <%1 |
| 22 | acikerisim.kku.edu.tr<br>İnternet Kaynağı | <%1 |
| 23 | docplayer.biz.tr | |

İnternet Kaynağı <%1

| | | |
|---|---|---|
| 24 | www.icondata.org<br>İnternet Kaynağı | <%1 |
| 25 | Bölükbaşı, İsmail Buğra. "Dengesiz Bir Diyabet Veri Setinde Makine Öğrenmesi Yöntemlerini Kullanarak Diyabet Hastalığının Teşhisi", Bursa Uludag University (Turkey), 2023<br>Yayın | <%1 |
| 26 | Yigithan Genis, Eda Akman Aydin. "Diagnosis of Epilepsy Disease with Deep Learning Methods Using EEG Signals", 2022 30th Signal Processing and Communications Applications Conference (SIU), 2022<br>Yayın | <%1 |
| 27 | openaccess.hacettepe.edu.tr:8080<br>İnternet Kaynağı | <%1 |
| 28 | Aksüngü, Sefa. "Gıda Sektöründeki Fiyat Tahminlemesi Için Yapay Sinir Ağları Modellerinin Incelenmesi ve Karşılaştırılması", Dokuz Eylul Universitesi (Turkey), 2024<br>Yayın | <%1 |
| 29 | Gümüşdağ, Tunç. "Derin Öğrenme Kullanarak Türkçe Için bir Kelime Anlamı Belirginleştirme Uygulaması", Maltepe University (Turkey), 2024<br>Yayın | <%1 |
| 30 | Saleh, Abdelrahman Amr Ali Rabie Elsayed. "Yari-Nemli Iklim Kosullarinda Surdurulebilir Su Yonetimi Icin Derin ogrenme Kullanilarak Referans Bitki Su Tuketiminin Tahmin Edilmesi", Bursa Uludag University (Turkey), 2021<br>Yayın | <%1 |
| 31 | Saruhan, Vedat. "Ekstrüzyon yöntemiyle üretilen lif takviyeli harçların reolojik davranışı | <%1 |

| | | |
|---|---|---|
| 32 | acikerisim.bingol.edu.tr:8080<br>İnternet Kaynağı | <%1 |
| 33 | gcris.ktun.edu.tr<br>İnternet Kaynağı | <%1 |
| 34 | johschool.com<br>İnternet Kaynağı | <%1 |
| 35 | www.bursahayat.com.tr<br>İnternet Kaynağı | <%1 |
| 36 | www.gundemtube.com<br>İnternet Kaynağı | <%1 |
| 37 | Ürgenç, Sergül. "Makine öğrenmesi yöntemleri ile bitcoin trend dönüşlerinin tahmin edilmesi.", Mimar Sinan Fine Arts University (Turkey), 2024<br>Yayın | <%1 |
| 38 | 369485e5-78d9-4695-8ee7-77e624124993.filesusr.com<br>İnternet Kaynağı | <%1 |
| 39 | Kitapcı, Orçun. "Derin öğrenme modelleri ile elektrik kesinti tahmini", Istanbul Sabahattin Zaim University (Turkey) | <%1 |

| | | |
|---|---|---|
| 40 | Meihui Shi, Derong Shen, Yue Kou, Tiezheng Nie, Ge Yu. "Next point-of-interest recommendation by sequential feature mining and public preference awareness", Journal of Intelligent & Fuzzy Systems, 2021 | <%1 |

| | | |
|---|---|---|
| | Yayın | |
| 41 | dergipark.org.tr<br>İnternet Kaynağı | <%1 |
| 42 | dspace.baskent.edu.tr:8080<br>İnternet Kaynağı | <%1 |
| 43 | euroasiajournal.org<br>İnternet Kaynağı | <%1 |
| 44 | slidelegend.com<br>İnternet Kaynağı | <%1 |
| 45 | ufal.mff.cuni.cz<br>İnternet Kaynağı | <%1 |
| 46 | www.patika.dev<br>İnternet Kaynağı | <%1 |
| 47 | www.researchgate.net<br>İnternet Kaynağı | <%1 |
| 48 | Kalyoncu, Seyda. "Borsa Analizi Ve Tahmini İçin Derin Öğrenme Ağlari", Istanbul Sabahattin Zaim University (Turkey)<br>Yayın | <%1 |
| 49 | Bozdemir, Mehmet. "Makine çevirisi Ile Türkçe Sözel Ifadelerin Python Sözdiziminin Oluşturulması", Bursa Uludag University (Turkey), 2023<br>Yayın | <%1 |
| 50 | Saran, Murat Sabri. "Graf Teorisinin Bazı Mühendislik Uygulamaları", Balikesir University (Turkey), 2024<br>Yayın | <%1 |

| | | |
|---|---|---|
| 6 | www.fastercapital.com<br>İnternet Kaynağı | <%1 |
| 7 | Wei Yao, Mihai Datcu. "Deep Neural Networks Based Semantic Segmentation for Optical Time Series", IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, 2018<br>Yayın | <%1 |
| 8 | "Socioscientific Issues Focused Teacher Education", Springer Science and Business Media LLC, 2024<br>Yayın | <%1 |
| | anjs.edu.iq | |
| 9 | İnternet Kaynağı | <%1 |
| 10 | uvadoc.uva.es<br>İnternet Kaynağı | <%1 |
| 11 | www.repository.smuc.edu.et<br>İnternet Kaynağı | <%1 |
| 12 | Emir Oncu, Kadriye Yasemin Usta Ayanoglu, Fatih Ciftci. "Comparative analysis of deep learning models for predicting biocompatibility in tissue scaffold images", Computers in Biology and Medicine, 2025<br>Yayın | <%1 |
| 13 | dergipark.org.tr<br>İnternet Kaynağı | <%1 |
| 14 | "Future Data and Security Engineering. Big Data, Security and Privacy, Smart City and Industry 4.0 Applications", Springer Science and Business Media LLC, 2023<br>Yayın | <%1 |
| 15 | www.frontiersin.org<br>İnternet Kaynağı | <%1 |

| | | |
|---|---|---|
| 16 | Yankun Xue, Chunying Kang, Hongcheng Yu. "HAE-HRL: A network intrusion detection system utilizing a novel autoencoder and a hybrid enhanced LSTM-CNN-based residual network", Computers & Security, 2025<br>Yayın | <%1 |
| 17 | 123dok.org<br>İnternet Kaynağı | <%1 |

# ÖZGEÇMİŞ

## KİŞİSEL BİLGİLER

| | |
|---|---|
| **Adı Soyadı** | **Yunus DUYAR** |

## EĞİTİM BİLGİLERİ

| Derece | Kurum | Mezuniyet Yılı |
|---|---|---|
| **Lise** | **Baki-Ayşe Simitçioğlu Anadolu Lisesi** | **2014** |
| **Lisans** | **Niğde Ömer Halisdemir Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği** | **2021** |
| **Yüksek Lisans** | **Kayseri Üniversitesi Elektrik-Elektronik Mühendisliği** | **2025** |

## İŞ DENEYİMLERİ

| Derece | Kurum | Görev Süresi |
|---|---|---|
| **Satış Uzmanı** | **Aksa Jeneratör Satış Ve Pazarlama A.Ş.** | **2023 – Halen** |
| **Elektrik-Elektronik Mühendisi** | **Korflame Bacasız Şömine Sistemleri** | **2023-2023** |
| **Elektrik-Elektronik Mühendisi** | **İkon Aydinlatma Mühendislik İmalat San. Tic. Ltd. Şti** | **2022-2022** |

## YAYINLAR

Duyar, Y., Emlek, A., & Mengüç, E. C. (2023). Kompleks Değerli Veriler Kullanılarak Derin Öğrenme Yöntemleri ile Rüzgar Hızı ve Yönü Tahmini. *5. Uluslararası Türk Dünyası Fen Bilimleri ve Mühendislik Kongresi (TURK-COSE 2023), Bişkek, Kırgızistan*, 1–4.

YUNUS DUYAR

YÜKSEK LİSANS TEZİ

2025

Uygulama ve Proje Odaklı, İş Dünyası ile Bütünleşen Üniversite