



**İKİNCİL AYRIŞTIRMA TEKNİĞİ KULLANARAK  
YAPAY SİNİR AĞI TEMELLİ ÇOK ADIMLI  
RÜZGAR HIZI TAHMİNİ**

**MUSTAFA TAN**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ  
ANA BİLİM DALI**

**Dr. Öğr. Üyesi CEM EMEKSİZ**

**Ocak - 2020**

**Her hakkı saklıdır**

T.C.  
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

İKİNCİL AYRIŞTIRMA TEKNİĞİ KULLANARAK YAPAY SİNİR AĞI  
TEMELLİ ÇOK ADIMLI RÜZGAR HIZI TAHMİNİ

MUSTAFA TAN

TOKAT  
Ocak - 2020

Her hakkı saklıdır

Mustafa TAN tarafından hazırlanan "İkincil Ayrıştırma Tekniği Kullanarak Yapay Sinir Ağı Temelli Çok Adımlı Rüzgar Hızı Tahmini" adlı tez çalışmasının savunma sınavı 22 OCAK 2020 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği / Oy Çokluğu ile Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman  
Dr. Öğr. Üyesi CEM EMEKSİZ

Üye  
Doç. Dr. Ünal KURT  
Amasya Üniversitesi

Üye  
Dr. Öğr. Üyesi A. Hakan YAVUZ  
Tokat Gaziosmanpaşa Üniversitesi

  
.....  
  
.....  
  
.....

ONAY

  
.....  
Prof. Dr. Çetin ÇEKİCİ  
Fen Bilimleri Enstitüsü Müdürü

22/01/2020

## TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdiği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.



Mustafa TAN

22 Ocak 2020

## ÖZET

### YÜKSEK LİSANS TEZİ

#### İKİNCİL AYRIŞTIRMA TEKNİĞİ KULLANARAK YAPAY SİNİR AĞI TEMELLİ ÇOK ADIMLI RÜZGAR HIZI TAHMİNİ

MUSTAFA TAN

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

(TEZ DANIŞMANI:DR. ÖĞR. ÜYESİ CEM EMEKSİZ)

Son yıllarda, elektrik enerji şebekelerine rüzgar enerjisi üretimini entegre etmenin önemi hızla artmaktadır. Elektrik şebekesi içine rüzgar enerjisini entegre etmenin en büyük zorluğu, rüzgar enerjisinin değişkenliği ve süreksizliğidir. Bu durumla başa çıkmak için en iyi yaklaşım, rüzgar enerjisi üretiminin gelecekteki değerlerini tahmin etmektir. Yüksek doğrulukları ile rüzgar hızı tahmin yöntemleri bu sorunları en aza indirmek için kullanılabilir etkili bir araçtır. Bu çalışmada model olarak veri ön işleme, kümeleme, tahmin ve değerlendirme olmak üzere 4 modülden oluşan hibrit bir tahmin sistemi önerilmiştir. Çalışmada kullanılan rüzgar hızı verilerini Gaziosmanpaşa Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi yerleşkesinde kurulan rüzgar ölçüm istasyonundan elde edilmiştir. Bu istasyonda kullanılan sensörler aracılığı ile ölçülen rüzgar hızı verileri 10'ar dakika ara ile toplanmış olup bir yıllık veriler üzerinde çalışma yapılmıştır. Önerilen model, veri ön işlemede, ham veri serisi içindeki gürültünün etkisini azaltmak ve özellikleri çıkartmak için yüksek frekanslı sinyallerin kaldırılmasında ayrıştırma teknikleri, veri kümeleme modülünde rüzgar hızı verileri içindeki benzerlik özelliğini çıkarmak için hurst üstel katsayısı, geri yayımlı yapay sinir ağlarını içeren tahmin modelleri ve yüksek dereceli ve prestijli olarak yayınlanan en son araştırma bulgularına (MAPE, RMSE,  $R^2$ ) dayanmaktadır. Analiz sonuçları önerilen yenilikçi hibrit modelin tahmin doğruluğu açısından karşılaştırılan geleneksel tahmin modellerinden (EEMD-VDM-BPNN and EEMD-EWT-BPNN) daha iyi performans göstermektedir. Önerilen hibrit modelde elde edilen MAPE değerleri kıyaslandığında geleneksel modellerde elde edilenlere göre sırasıyla %41.16 ve %78.80 azalmıştır.

2020, 101 SAYFA

**ANAHTAR KELİMELER:** Yenilenebilir Enerji, Rüzgar Hızı Tahmini, Ayrıştırma Teknikleri

## **ABSTRACT**

### **MASTER THESIS**

#### **MULTI-STEP WIND SPEED ESTIMATION BASED ON ARTIFICIAL NEURAL NETWORK USING SECONDARY SEPARATION TECHNIQUE**

**MUSTAFA TAN**

**TOKAT GAZIOSMANPASA UNIVERSITY  
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

**DEPARTMENT OF ELECTRICAL ENGINEERING**

**(SUPERVISOR: ASST. PROF. DR. CEM EMEKSİZ)**

In recent years, the importance of integrating the production of wind energy into electrical energy networks has been increasing rapidly. The biggest challenge to integrate wind energy into the power grid wind power is variability and discontinuity. To deal with this situation, the best approach is to predict future values of wind power production. Wind speed estimation methods with high accuracy are an effective tool that can be used to minimize these problems. In this study, a hybrid estimation system consisting of 4 modules as data preprocessing, clustering, estimation and evaluation has been proposed as a model. The meteorological parameters used in the study were obtained from the wind measurement station build in the campus of Engineering and Nature Science Faculty in Gaziosmanpaşa University. The wind speed was measured in the 10 minutes intervals via censors used in this station and one-year data was included in the analysis. The proposed model is based on decomposition techniques for the elimination of high frequency signals to reduce the effect of noise in the raw data series and to extract features in data preprocessing, the hurst exponential coefficient in order to extract the similarity property in the wind speed data in the data clustering module, prediction models involving back propagation artificial neural networks and the latest research findings (MAPE, RMSE,  $R^2$ ) published in high grade and prestigious. The results of the analysis perform better than the traditional prediction models (EEMD-VDM-BPNN and EEMD-EWT-BPNN) compared in terms of predictive accuracy of the proposed innovative hybrid model. When the MAPE values obtained in the proposed hybrid model are compared, they are decreased by 41.16% and 78.80%, respectively, compared to those obtained in traditional models.

2020, 101 PAGE

**KEYWORDS:** Renewable Energy, Wind Speed Estimation, Decomposition Techniques

## ÖNSÖZ

Tezimin hazırlanmasında danışmanlığımı yapan, tez için kullandığım verileri temin eden, bilgisini ve tecrübesini çalışmamın her aşamasında benimle paylaşan, çok değerli hocam Sayın Dr. Öğr. Üyesi Cem EMEKSİZ'e, Tez Değerlendirme Jürisi olarak yaptıkları değerli katkılar sebebiyle hocalarım Sayın Doç. Dr. Ünal KURT'a ve Sayın Dr. Öğr. Üyesi A. Hakan YAVUZ'a teşekkürlerimi sunarım. Öğrenim hayatım boyunca bana emek veren, iyi ve güzel işler yapmanın önemini hayatıma dâhil ettiren tüm hocalarıma ve arkadaşlarıma teşekkürlerimi ve saygılarımı sunarım. Yüksek lisans yapmam için beni teşvik eden ve bu süreçte her zaman yanımda olan sevgili eşim Sündüs TAN'a teşekkür ederim.

**MUSTAFA TAN**

**22 Ocak 2020**

## İÇİNDEKİLER

### Sayfa

ÖZET .....	i
ABSTRACT.....	ii
ÖNSÖZ .....	iii
İÇİNDEKİLER .....	iv
SİMGELER ve KISALTMALAR.....	vi
ŞEKİL LİSTESİ.....	x
ÇİZELGE LİSTESİ.....	xii
1. GİRİŞ .....	1
2. LİTERATÜR TARAMASI .....	5
3. DÜNYADA ve TÜRKİYE'DE ENERJİ DURUMU .....	11
3.1. Dünyada Birincil Enerji ve Rüzgar Enerjisi Potansiyeli.....	11
3.2. Türkiye'de Birincil Enerji ve Rüzgar Enerjisi Potansiyeli .....	14
4. RÜZGAR GÜCÜ ve RÜZGAR HIZI TAHMİNLEMESİ .....	20
4.1. Rüzgar Hızı Tahminlerinin Sınıflandırılması .....	25
4.1.1. Rüzgar hızı tahminlerinin zaman bazında sınıflandırılması .....	26
4.1.2. Rüzgar hızı tahminlerinin yöntem bazında sınıflandırılması.....	27
4.1.3. Devamlılık metodu .....	28
4.1.4. Fiziksel yaklaşımlar .....	28
4.1.5. İstatistiksel yaklaşımlar .....	29
4.1.6. Hibrit modeller.....	30
4.2. Ayırıştırma Teknikleri.....	31
4.2.1. Ampirik dalgacık dönüşümü (Empirical Wavelet Transform).....	34
4.2.2. Ampirik mod ayırıştırma (Empirical Mode Decomposition) .....	35
4.2.3. Topluluk ampirik mod ayırıştırma (Ensemble Empirical Mode Decomposition Method) .....	38
4.2.4. Varyasyonel mod ayırıştırma (Validation mode decomposition).....	39
5. MATERYAL ve YÖNTEM.....	40
5.1. Uyarlanabilir Gürültüyle Tamamlanan Topluluk Ampirik Mod Ayırıştırma (Complete Ensemble Empirical Mode Decomposition Adaptive Noise)....	43



<b>5.2. Lokal Ortalama Ayrıştırması (Local Mean Decompositon) .....</b>	<b>45</b>
<b>5.3. Hurst Üstel Katsayısı .....</b>	<b>47</b>
<b>5.4. Geri Yayılımlı Sinir Ağı (Back Propagation Neurol Network) .....</b>	<b>49</b>
<b>5.5. Hibrit Modelin Uygulama Prosedürleri .....</b>	<b>52</b>
<b>5.6. Performans Değerlendirme Kriterleri .....</b>	<b>54</b>
<b>6. ARAŞTIRMA BULGULARI ve TARTIŞMA.....</b>	<b>55</b>
<b>6.1. Vaka 1 .....</b>	<b>55</b>
<b>6.2. Vaka 2 .....</b>	<b>60</b>
<b>6.3. Vaka 3 .....</b>	<b>81</b>
<b>7. SONUÇLAR .....</b>	<b>87</b>
<b>8. KAYNAKLAR .....</b>	<b>91</b>
<b>9. EKLER.....</b>	<b>98</b>
<b>10. ÖZGEÇMİŞ .....</b>	<b>99</b>

## SİMGELER ve KISALTMALAR

Simgeler	Açıklama
$a$	İvme
$A$	Süpürme alanı
$C_p$	Türbin verimi
$D$	Fraktal katsayı
$E_k$	Kinetik enerji
$G$	Gradyan kuvveti
$GW$	Gigawatt
$H$	Hurst üstel katsayısı
$H_{ref}$	Ölçümün yapıldığı yükseklik
$KW$	Kilowatt
$m$	Kütle
$MW$	Havanın moleküler ağırlığı
$MW$	Megawatt
$n$	Mol Sayısı
$P$	Mutlak basınç
$P_r$	Rüzgarın iş yapabilme yeteneği
$P_t$	Rüzgarın türbin kanatlarına yapacağı basınç
$R$	İdeal gaz sabiti
$R$	Rüzgarın döner yarıçapı
$T$	Kelvin cinsinden mutlak sıcaklık
$V$	Hacim
$V$	Rüzgar hızı
$\Delta P$	İzobarlar arası basınç
$\lambda$	Kanat uç hız oranı
$\mu$	Hellmann katsayısı
$\omega$	Açısal dönme hızı

$\Omega$	Dünyanın açısal dönüş hızı
$\rho h$	Hava yoğunluğu
kWh	Kilowatt saat
GWh	Gigawatt saat
MWe	Megawatt enerji
MWt	Megawatt ısı

### **Kısaltmalar Açıklama**

AM	Genlik modülasyonu
ANFIS	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Network Based Fuzzy Inference Systems)
AR	Otoregresif
ARMA	Otoregresif hareketli ortalama
ARIMA	Otoregresif Entegre Hareketli Ortalama
BP	Geri yayılım (Back Propagation)
BPNN	Geri yayımlı sinir ağı (Back Propagation Neurol Network)
CC	Korelasyon Katsayısı(Correlation coefficient)
CLSPPA	Kaotik yerel arama ile çiçek tozlaşma algoritması (The flower pollination algorithm with chaotic local search)
CEEMDAN	Uyarlanabilir gürültülü bütünleşik ampirik mod ayrıştırma (Complete Ensemble Empirical Mode Decomposition Adaptive Noise)
CO <sub>2</sub>	Karbondioksit
CO	Karbonmonoksit
CH <sub>4</sub>	Metan
CSO	Çapraz Optimizasyon (Crisscross Optimization)
CSA	Eşleşmiş simüle tavlama (Coupled Simulated Annealing)
COA	Çapraz optimizasyon algoritması (Cross Optimization Algorithm)
EWT	Ampirik dalgacık dönüşümü (Empirical Wavelet Transform)
ELM	Aşırı öğrenme makineleri (Extreme Learning Machines)
EMD	Ampirik mod ayrıştırma
EPDK	Enerji Piyasası Düzenleme Kurulu
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
EEMD	Topluluk ampirik mod ayrıştırma (Ensemble Empirical Mode Decomposition)

EPSO	Evrimsel parçacık sürü optimizasyonu (Evolutionary Particle Swarm
FM	Frekans modülasyonu
FPA	Çiçek tozu algoritması (Flower-Pollination Algorithm)
GA	Genetik algoritma
GRNN	Genelleştirilmiş Regresyon Sinir Ağları (Generalized Regression Neural Network)
GWEC	Küresel Rüzgar Enerjisi Konseyi (Global Wind Energy Council)
GSA	Yerçekimi arama algoritması
HEA	Hibrit evrimsel uyarlama (Hybrid Evolutionary Adaptive)
HT	Hilbert transform
IA	Anlık genlik
IMF	İçsel Salınım Fonksiyonlarına (Intrinsic Mode Function)
IF	Anlık frekans
IEA	Uluslararası Enerji Ajansı (International Energy Agency)
ITD	İçsel Zaman Ölçeği Ayırıştırması
kNN	k-En Yakın Komşu ( K Nearest Neighbor)
KFCM	Çekirdek Bazlı Bulanık C-Aracı Kümeleme (Kernel-based fuzzy c-means clustering)
LPG	Sıvılaştırılmış Petrol Gazı
LMD	Lokal Ortalama Ayırıştırması (Local Mean Decompositon)
LSSVM	En küçük kare destek vektör makinesi (Least Square Support Vector Machine)
MAPE	Ortalama mutlak hata yüzdesi (Mean Absolute Percent Error)
MGM	Meteoroloji Genel Müdürlüğü
MSE	Ortalama Karesel Hata (Mean Square Error)
MOSBO	Çok amaçlı saten çardak kuşu optimizasyon
MTEP	Milyon ton eşdeğer petrol
MTA	Maden Tetkik ve Arama Genel Müdürlüğünün
NARX	Doğrusal Olmayan Otoresif Eksojen (Non-linear Auto-Regressive Exogenous)
NN	Sinir Ağı (Neural Network)
NNCT	Olumsuz olmayan kısıtlama teorisi (no negative constraint theory)
NO	Azot oksit
OECD	Ekonomik Kalkınma ve İşbirliği Örgütü (Organisation for Economic Co-operation and Development )
RBFNN	Radyal temel fonksiyon sinir ağı

RES	Rüzgar Enerji Santrelleri
RİTM	Rüzgar Gücü İzleme ve Tahmin Merkezi
R <sup>2</sup>	Determinasyon katsayısı (Determination Coefficient)
RMSE	Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)
RMSE	Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)
PF	Üretim fonksiyonu (product function)
SAM	Mevsimsel Ayarlama Yöntemi
SMO	Sıralı Minimal Optimizasyon (Sequential Minimal Optimisation)
SVR	Destek vektör regresyon
SHT	Sayısal Hava Tahmini
SO <sub>2</sub>	Kükürtdioksit
YSA	Yapay Sinir Ağı
WNN	Dalgacık sinir ağ (Wavelet Neural Network)
TEİAŞ	Türkiye Elektrik iletim A.Ş.
TÜREB	Türkiye Rüzgar Enerjisi Birliği
WPD	Dalgacık Paket Dönüşümü (Wavelet Packet Decomposition)
YEK	Yenilenebilir Enerji Kaynaklarının
VMD	Varyasyonel Mod Ayrıştırma (Validation mode decomposition)

## ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 3.1. Dünyada Yıllara göre Birincil Enerji Kullanımı.....	11
Şekil 3.2. Dünyada 2018 Yılı Birincil Enerji Kullanımı.....	12
Şekil 3.3. Dünyada toplam rüzgar enerji kurulumlarının yıllara göre gelişimi.....	13
Şekil 3.4.a) 2018 Karasal yeni tesisler.....	13
Şekil 3.4.b) 2018 Deniz üstünde yeni tesisler.....	13
Şekil 3.5. Kaynak bazlı 2018 yılı elektrik üretimi.....	15
Şekil 3.6. 2019 yılı ilk yarısı itibarıyla kurulu gücümüz.....	15
Şekil 3.7. Türkiye’de toplam kurulu rüzgar gücü kapasitesi.....	16
Şekil 3.8. Türkiye rüzgar enerjisi potansiyeli.....	19
Şekil 4.1. Betz kanunu.....	22
Şekil 4.2. Ayrıştırma Tabanlı Model Yapısı.....	32
Şekil 4.3. Ayrıştırma Tabanlı Hibrit Sistemlerin Sınıflandırılması.....	33
Şekil 5.1. Ölçüm Direği.....	40
Şekil 5.2. Güç Kutusu.....	41
Şekil 5.3. Haftalık ve Mevsimsel Veri Setleri.....	42
Şekil 5.4. Temel Yapay Sinir Ağı Hücresi.....	50
Şekil 5.5. Geri Beslemeli YSA.....	51
Şekil 5.6. Çalışmada kullanılan hibrit modelin ana yapısı.....	53
Şekil 6.1. Haftalık veriye ait CEEMDAN tekniği sonrası elde edilen IMFler.....	55
Şekil 6.2. Haftalık veriye ait LMD kullanılarak ayrıştırılmış IMF1 serisi.....	56
Şekil 6.3. Haftalık veriye ait çeşitli bileşenlerin hurst analizi.....	56
Şekil 6.4. Haftalık veriye ait üç alt kümede gruplandırılan verilerin değişimi.....	57
Şekil 6.5.a) Haftalık veriye ait MAPE Hata değeri.....	58
Şekil 6.5.b) Haftalık veriye ait RMSE hata değeri.....	58
Şekil 6.5.c) Haftalık veriye ait R <sup>2</sup> Hata değeri.....	58
Şekil 6.6. Haftalık tahmin sonuçlarının grafiksel gösterimi.....	60
Şekil 6.7. Kış mevsimine ait CEEMDAN tekniği sonrası elde edilen IMFler.....	61
Şekil 6.8. Kış mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi.....	62
Şekil 6.9. Kış mevsimine ait üç alt kümede gruplandırılan verilerin değişimi.....	63
Şekil 6.10.a) Kış mevsimine ait MAPE Hata değeri.....	63
Şekil 6.10.b) Kış mevsimine ait RMSE Hata değeri.....	63
Şekil 6.10.c) Kış mevsimine ait R <sup>2</sup> Hata değeri.....	64
Şekil 6.11. Kış mevsimi tahmin sonuçlarının grafiksel gösterimi.....	65
Şekil 6.12. Yaz mevsimine ait CEEMDAN tekniği sonrası elde edilen IMFler.....	66
Şekil 6.13. Yaz mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi.....	67
Şekil 6.14. Yaz mevsimine ait üç alt kümede gruplandırılan verilerin değişimi.....	68
Şekil 6.15.a) Yaz mevsimine ait MAPE Hata değeri.....	68

**Şekil****Sayfa**

Şekil 6.15.b) Yaz mevsimine ait RMSE Hata değeri.....	68
Şekil 6.15.c) Yaz mevsimine ait $R^2$ Hata değeri.....	69
Şekil 6.16. Yaz mevsimi tahmin sonuçlarının grafiksel gösterimi.....	70
Şekil 6.17. İlkbahar mevsimine ait CEEMDAN tekniği ile elde edilen IMFler.....	71
Şekil 6.18. İlkbahar mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi.....	72
Şekil 6.19. İlkbahar mevsimine ait üç alt kümede gruplandırılan veriler.....	73
Şekil 6.20.a) İlkbahar ayna ait MAPE Hata değeri.....	73
Şekil 6.20.b) RMSE Hata değeri.....	73
Şekil 6.20.c) İlkbahar mevsimine ait $R^2$ Hata değeri.....	74
Şekil 6.21. İlkbahar mevsimi tahmin sonuçlarının grafiksel gösterimi.....	75
Şekil 6.22. Sonbahar mevsimine ait CEEMDAN tekniği ile elde edilen IMFler.....	76
Şekil 6.23. Sonbahar mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi.....	76
Şekil 6.24. Sonbahar mevsimine ait üç alt kümede gruplandırılan veriler.....	78
Şekil 6.25.a) Sonbahar mevsimine ait MAPE Hata değeri.....	78
Şekil 6.25.b) RMSE Hata değeri.....	78
Şekil 6.25.c) Sonbahar mevsimine ait $R^2$ Hata değeri.....	79
Şekil 6.26. Sonbahar mevsimi tahmin sonuçlarının grafiksel gösterimi.....	80

## ÇİZELGE LİSTESİ

<u>Çizelge</u>	<u>Sayfa</u>
Çizelge 1.1. Enerji Kaynaklarının Sınıflandırılması.....	2
Çizelge 1.2. Dünyada enerjinin dönüşümünü .....	3
Çizelge 4.1. Zaman bazında sınıflandırılması ve uygulamaları.....	26
Çizelge 4.2. EMD ve geliştirilmiş versiyonlarının karşılaştırılması.....	38
Çizelge 5.1. Haftalık ve Mevsimsel veri setine ait istatiksıl bilgiler.....	42
Çizelge 6.1. Haftalık veriye ait Hurst üstel katsayısı.....	57
Çizelge 6.2. Haftalık veriye ait tahmin modellerinin performansları.....	59
Çizelge 6.3. Kış mevsimine ait Hurst üstel katsayısı.....	62
Çizelge 6.4. Kış mevsimi tahmin sonuçlarının karşılaştırılması.....	64
Çizelge 6.5. Yaz mevsimine ait Hurst üstel katsayısı.....	67
Çizelge 6.6. Yaz mevsimi tahmin sonuçlarının karşılaştırılması.....	69
Çizelge 6.7. İlkbahar mevsimine ait Hurst üstel katsayısı.....	72
Çizelge 6.8. İlkbahar mevsimi tahmin sonuçlarının karşılaştırılması.....	74
Çizelge 6.9. Sonbahar mevsimine ait Hurst üstel katsayısı.....	77
Çizelge 6.10. Sonbahar mevsimi tahmin sonuçlarının karşılaştırılması.....	79
Çizelge 6.11. Haftalık veri seti üzerinden hibrit modellerin karşılaştırılması.....	81
Çizelge 6.12. İlkbahar veri seti üzerinden hibrit modellerin karşılaştırılması.....	82
Çizelge 6.13. Kış veri seti üzerinden hibrit modellerin karşılaştırılması.....	83
Çizelge 6.14. Sonbahar veri seti üzerinden hibrit modellerin karşılaştırılması.....	84
Çizelge 6.15. Yaz veri seti üzerinden hibrit modellerin karşılaştırılması.....	85
Çizelge 7.1. Verilerden elde edilen en iyi hata metrikleri.....	88



# 1. GİRİŞ

İnsanlar tüm tarihi süreçlerde çeşitli enerji türlerine ihtiyaç hissetmişlerdir. Bunun içinde birçok canlı gibi sadece vücutlarına aldıkları enerjiyle yetinmemişler ve diğer enerji kaynakları keşfederek bu kaynaklarını da farklı teknolojiler geliştirerek ısı, mekanik ve elektrik enerjisine çevirmeyi öğrenmişlerdir (Aslan ve Yamak 2006).

Dünyadaki nüfus artışıyla orantılı olarak artan enerji talepleri her geçen gün farklı boyutlara ulaşmakla birlikte enerji, ülkelerin ekonomik ve sosyal gelişmelerinin de en önemli işaretlerinden biridir. Ülkelerin artan enerji talepleri bu hususta uzun vadeli, planlı ve bilimsel çalışmalar yapmayı gerektirmektedir. Günümüzde nüfus artışının dışında hızla ilerleyen teknolojik gelişmelere bağlı olarak; endüstri 4.0, 5G mobil şebeke hizmetleri, nesnelerin interneti platformu ile akıllı kentler, yüksek yaşam deneyimleri nedeniyle de enerji ihtiyacı gün geçtikçe artmaktadır.

Genel olarak enerjinin herhangi bir dönüşüm veya değişime maruz kalmamış haline birincil enerji denilmektedir. Birincil enerji kaynakları; petrol, kömür, doğal gaz, nükleer, hidrolik, biokütle, dalga-gelgit, güneş ve rüzgardır. Birincil enerjinin dönüşümü sonucu elde edilen enerjiye de ikincil enerji denilmektedir. Elektrik, benzin, mazot, motorin, kok kömürü, hava gazı, sıvılaştırılmış petrol gazı (LPG) bu tip enerji kaynaklarıdır. Birincil ve ikincil enerji kaynaklarının dağılımı Çizelge 1.1’de gösterilmektedir (Koç ve Şenel, 2013).

Çizelge 1.1. Enerji Kaynaklarının Sınıflandırılması. (Koç ve Şenel, 2013)

<b>ENERJİ KAYNAKLARI</b>			
<b>Kullanımlarına Göre</b>		<b>Dönüştürülebilirliklerine Göre</b>	
<b>Yenilenemez</b>	Fosil Kaynaklı	<b>Birincil (Primer)</b>	Kömür
	Kömür		Petrol
	Petrol		Doğalgaz
	Doğalgaz		Nükleer
	Çekirdek Kaynaklı		Biyokütle
Uranyum	Hidrolik		
Toryum	Güneş		
<b>Yenilenebilir</b>	Hidrolik		Rüzgar
	Güneş		Dalga, Gel-git
	Biyokütle		<b>İkincil (Seconder)</b>
	Rüzgar	İkincil Kömür	
	Jeotermal	Kok, Petrokok	
	Dalga, Gel-git	Hava gazı	
	Hidrojen	Sıvılaştırılmış Petrol Gazı (LPG)	

Dünyada dönemsel enerji dönüşüm ve sınıflandırılmaları Çizelge 1.2’de gösterilmektedir. Son yüzyılda, yenilenebilir enerji kaynaklarına ait çalışmalar dünya çapında teknolojik bilgiler ışığında takip edilmektedir. Enerji, mecburi bir ihtiyaç olup bir ülkenin kalkınma potansiyelini göstermektedir. Gelişmiş toplumla enerji tüketimi arasında paralel bir ilişki olup, ekonominin gelişmesi ve refah seviyesinin yükselmesiyle enerji tüketim talebinin hızlandığı görülmektedir (Koç ve Kaplan, 2008).

Çizelge 1.2 Dünyada enerjinin dönüşümünü

<b>Dönem</b>	<b>1700 – 1900</b>	<b>1900 – 2000</b>	<b>2000 – ?</b>
<b>Kaynak</b>	Toprak	Sermaye	Bilgi
<b>Enerji</b>	Kas gücü	Fosil Yakıtlar	Yenilebilir Enerjiler
<b>Rekabet</b>	Lokal	Ulusal	Global
<b>Bağlantılar</b>	Minimal	Fark edirlilik	Süreklilik

Son yıllarda enerjiye güvenilir kaynaklardan, en ucuz ve en kaliteli yöntemlerle ulaşmak oldukça önemlidir. Çünkü günümüzde hala enerji ihtiyacının büyük bir bölümünün fosil kaynaklı yakıtlardan elde edilmesi ve bu yakıtların sınırlı rezervlere sahip olması çalışmaları yenilenebilir enerji kaynaklarına yönlendirmiştir. Ayrıca fosil yakıtlar zararlı gazların salınımına (Karbon dioksit (CO<sub>2</sub>), Karbonmonoksit (CO), Metan (CH<sub>4</sub>), Kükürtdioksit (SO<sub>2</sub>), Azot oksit (NO), nükleer enerji radyoaktif atıkların oluşumuna sebep olurken küresel ısınma ve asit yağmurlarına da neden olurlar. Bu sebeplerden dolayı artan araştırmalar, teknolojik gelişmeler ve uygulanan enerji politikaları neticesinde yenilenebilir enerji projelerinin maliyetlerinde fosil yakıtlara nazaran makul düzeylere düşüşler olduğu görülmektedir (Cantürk, 2018). Özellikle 1973 petrol krizi ve sonrasında meydana gelen iki nükleer reaktör kazası yenilenebilir enerji kaynaklarına olan ilginin artmasına neden olmuştur. Bununla birlikte gelişen teknoloji ve azalan maliyetler, geleceğin enerji ihtiyacının yenilenebilir enerji kaynaklarından sağlanması gerekliliğini ön plana çıkarmaktadır (Canpolat, 2013). Rüzgar enerjisi yenilenebilir enerji kaynakları arasında en popüler enerji türüdür. Çünkü rüzgar enerjisinin hem ham madde maliyeti yoktur hem de işletme giderleri de oldukça düşüktür. Bu avantajlar rüzgar enerjisinin planlama ve işletmesini çok önemli bir hale getirmiştir. Bu enerjiyi maliyet açısından avantajlı hale getiren faktörlerden biri de ilgili teknolojilerin ülkemizde de üretilmeye başlanmasıdır (Yağcı, 2013).

Rüzgar enerjisinden elektrik enerjisi üretimi son yıllarda ciddi çalışmaların olduğu bir bilim dalı haline gelmiştir. Rüzgar, atmosferik sınır tabaka yasasına dayanmakta olup

bölgelerin coğrafi özelliklerine de bağlıdır. Rüzgar enerjisi meteorolojisi, temel olarak bölgesel rüzgar potansiyeli analizi, rüzgar türbinlerinin yerleşimi ve kısa süreli rüzgar enerjisi tahminleri ile ilgilenmektedir.

2018 yılı sonunda Küresel Rüzgar Enerjisi Konseyi (GWEC, Global Wind Energy Council)'nin açıkladığı verilere göre dünya genelinde kurulu rüzgar gücü kapasitesi 591 GW'a ulaşırken, bu miktarın hemen hemen yarısının son 5 yıl içinde kurulduğu belirtilmektedir (Cantürk, 2018).

Çevresel açıdan sağladığı faydalara rağmen, rüzgar gücünün doğal belirsizliği, enerji sistemlerinin çalışmasında zorluklar doğurmaktadır. Rüzgar gücü tahmini, sistem operatörlerine gelecekteki zaman aralıklarında mevcut rüzgar gücü hakkında faydalı tahminler sağlamak için gerekli bir araç olarak kabul edilmektedir. Bu tür tahminler enerji dengeleme kaynaklarının programlanmasında uygulanır (Aoife ve ark., 2012; Jung ve Broadwater, 2014).

Rüzgar enerjisi diğer yenilenebilir enerji kaynaklarına kıyasla hem kurulum hem de işletim maliyeti açısından birçok avantajlara sahiptir. İnsanlar ilk zamanlar deneyimlerine göre gündelik yaşamlarında rüzgar enerjisinden faydalanırken, günümüzde rüzgar enerjisinden faydalanmak için rüzgarın dakika, saat, mevsim gibi hangi zaman aralıklarında, nerede, ne sıklıkta estiği gibi bilgiler hususiyet arz etmektedir. Özetle bir bölgeye rüzgar enerjisi santrali projelenebilmesinin ilk aşaması, bölgeden alınacak verilerin değerlendirilmesi ile gerçekleştirilir. Bu sebeple ölçümlerin kaliteli ve gerçekçi olması gereklidir (Yağcı, 2013).

Bu tez çalışması 7 ana bölümden oluşmaktadır. Birinci bölüm giriş kısmıdır. İkinci bölümü literatür taraması oluşturmaktadır. Üçüncü bölümde Dünya'daki ve Türkiye'deki rüzgar enerji potansiyelinden bahsedilmiştir. Dördüncü bölümde rüzgar gücü / hızı tahminlemesi konularına değinilmiş olup beşinci bölümü ise materyal ve metot oluşturmaktadır. Altıncı bölümde çalışmalar neticesinde elde edilen bulgular verilmiştir. Son bölüm olan yedinci bölümde ise çalışmaya ilişkin sonuçlar yorumlanarak sunulmuştur.

## 2. LİTERATÜR TARAMASI

Catalao ve ark. (2009) ise Portekiz'de kısa süreli rüzgar hızını tahmin etmek için bir yapay sinir ağı (YSA) yaklaşımı kullanarak Naive yöntem ve istatistiksel ARIMA yöntemleriyle karşılaştırmışlardır. Önerilen yapay sinir ağı (YSA) modeli, üç katmanlı ve Levenberg–Marquardt öğrenme algoritmasıyla tasarlanmışlar ve mevsimlerden rastgele seçilmiş bir gün için tahmin yapmışlar ve daha başarılı sonuçlar verdiğini belirtmişlerdir.

Kolhe ve ark. (2011) yaptıkları çalışmada kısa süreli rüzgar hızı tahminleri için genetik algoritma ile birlikte yapay sinir ağı (YSA) kullanarak hibrit bir model oluşturmuşlardır. Geliştirilen model, Tayvan Rüzgar Enerjisi şirketinin gerçek operasyonel sonuçları için test ve analizinde yapılan tahminlerin hata oranlarını düşürdüğü bildirilmiştir.

Kurbatskii ve ark. (2011) Hilbert Huang dönüşümünü ve sinir ağı tahminini birleştiren yeni bir uyarlamalı tahmin yaklaşımı geliştirmişlerdir. İlk olarak, Hilbert Huang dönüşümü ile zaman serilerini temel fonksiyonlara ayırmışlar ve elde edilen fonksiyonlar ile bunların anlık genlikleri daha sonra sinir ağı tahmininin girdi değişkenleri olarak kullanmışlardır.

Chang ve ark. (2012) yaptıkları çalışmada, yapay sinir ağları için en iyi girdi nöron sayılarını / parametrelerini tahmin durumunda incelemişler ve bunun için ayın ilk 20 gününü eğitim, son 10 gününü ise test verisi olarak belirlemişlerdir. Oluşturulan birden fazla tahmin model sonuçlarının genel olarak başarılı olduğu bildirilmiştir. Ayrıca hız ortalaması yüksek olan aylarda hata oranlarının çok düşük olduğu, hız ortalamasının düşük olduğu aylarda ise hata oranları yükseldiği fakat yine de iyi sonuçlar alındığı belirtilmiştir. Bununla birlikte uygun giriş parametrelerinin seçilmesi, çoklu parametrelerin seçilmesinden daha önemli olduğu da vurgulanmıştır.

Zhou ve ark. (2014), Topluluk ampirik mod ayrıştırma (EEMD, Ensemble Empirical Mode Decomposition Method)'ya ve genelleştirilmiş regresyon sinir ağına (GRNN, Generalized Regression Neural Network) dayanan bir hibrit yöntem önermişlerdir ve

deneysel olarak, EEMD tekniğinin tahmin doğruluğuna büyük katkılar sağladığını göstermişlerdir.

Catalao ve ark. (2015) ise geçmiş verileri kullanarak 3 saatlik zaman ufku gibi kısa süreli tahmin yapan bir model üzerinde çalışmışlardır. Önerdikleri model hibrit evrimsel uyarılma (HEA, Hybrid Evolutionary Adaptive) ağ yapısı olup dalgacık dönüşümü fonksiyonu ve evrimsel parçacık sürü optimizasyonu (EPSO, Evolutionary Particle Swarm Optimization) algoritması ile uyarılmalı ağ tabanlı bulanık çıkarım sisteminin (ANFIS, Adaptive Neuro-Fuzzy Inference System) birlikte kullanımıyla oluşturulmuştur. Mevsimsel ve aylık yapılan tahminler Naive yöntem, YSA ve YSA tabanlı çeşitli hibrit modellerin sonuçlarıyla karşılaştırmışlardır. Önerilen HEA modelin başarılı sonuçlar verdiği gibi çok kısa hesaplama süresi elde edildiği belirtilmiştir.

Chitsaz ve ark. (2015) tarafından geçmiş verilerin girdi olarak kullanıldığı bir dalgacık sinir ağ (WNN, Wavelet Neural Network) modeli oluşturulmuş ve dört mevsime ait verilerle modeli test edilirken Clonal seçim algoritması ile de veriyi optimize etmişlerdir. Literatürde daha kısa zaman adımları (10-15 dakika) kullanılırken, çalışmanın Alberta-Kanada olması ve elektrik piyasasının saatlik hesaplaması nedeniyle zaman adımının 1 saat olarak seçildiği belirtilmiştir. Önerilen yöntemin etkinliğini göstermek için, diğer birkaç rüzgar enerjisi tahmin tekniği ile karşılaştırmışlardır. Elde edilen sonuçlar, geliştirilen yaklaşımın geçerliliğini doğruladığını bildirmişlerdir.

Hu ve ark. (2015) önerdikleri hibrit model ile kısa vadeli rüzgar hızı tahminlemiştir. Modelde veri setinin belirsizliğini ve rastlantısallığını azaltmak için ampirik dalgacık dönüşümü (EWT, Empirical Wavelet Transform) kullanmışlar ve elde edilen alt grupların tahminlemesinde ise en küçük kare destek vektör makinesi (LSSVM, Least Square Support Vector Machine) tercih etmişlerdir. LSSVM'nin parametrelerini optimize etmek amacıyla eşleşmiş simüle tavlama (CSA, Coupled Simulated Annealing) algoritması kullanmışlardır.

Liu ve ark. (2015) yaptıkları çalışmada, rüzgar hızının doğru tahminini gerçekleştirmek için yeni bir hibrit tahmin mimarisi önermişlerdir. Bu mimaride, dört farklı sinyal modeli,

dört sinyal ayrıştırma algoritması (örneğin, dalgacık ayrıştırma / dalgacık paket ayrıştırma / ampirik mod ayrıştırma / hızlı seri empirik mod ayrıştırma) ve aşırı öğrenme makineleri (ELM, Extreme Learning Machines) birleştirilmiştir. Çalışmada elde edilen sonuçlara göre ELM'nin rüzgar hızı tahmini için daha uygun olduğunu bildirmişlerdir.

Meng ve ark. (2016) yaptıkları çalışmada Hollanda'da bulunan bir rüzgar gözlem istasyonundan toplanan rüzgar hızı serisini, kısa süreli rüzgar hızını tahminlemek için geri yayımlı sinir ağı (BPNN, Back Propagation Neurol Network)'na dayanan çapraz optimizasyon algoritması (COA, Cross Optimization Algorithm) ve WPD'nın kullanıldığı hibrit bir model oluşturmuşlar. Veri seti WPD ile alt sektörlere ayrıştırılıp COA ile optimize edilmiş ve BPNN ile çok adımlı tahminleme yapmışlardır.

Lydia ve ark. (2016) rüzgar hızını doğrusal ve doğrusal olmayan AR-MA modellerine dayanarak, rüzgar hızını tahmin için 10 dakika aralıkla bir saatlik modeller oluşturmuşlardır. Modellerin doğruluğunu, Ortalama Mutlak Hata, Kök Ortalama Kare Hatası ve Ortalama Mutlak Yüzde Hatası olmak üzere üç performans ölçümü kullanılarak ölçmüşlerdir.

Ren ve ark. (2016), ampirik mod ayrıştırma (EMD) ve destek vektör regresyon (SVR) yöntemlerini bütünleştirerek yeni bir rüzgar hızı tahmin yöntemi önermektedir. Önerilen EMD – SVR modeli, doğruluk veya hesaplama karmaşıklığı açısından yakın zamanda bildirilen birkaç yöntemi geride bıraktığını bildirmişlerdir.

Wang ve ark. (2016), çalışmalarında EEMD'na, genetik algoritma (GA)'ya ve BPNN'na dayalı bir hibrit tahmin yöntemi önermişlerdir. Çalışmalarında, orijinal zaman serilerini EEMD tarafından bir dizi daha durağan alt gruba ayırtmışlardır. Önerilen model ile çok kısa vadeli (10 dakika) ve kısa vadeli (1 saat) rüzgar hızı tahminlerine uygun olduğunu bildirmişlerdir.

Chang ve ark. (2017), kısa süreli rüzgar hızı ve gücünü tahminlemesi için gelişmiş radyal temel fonksiyon sinir ağı (RBFNN) modeli önerdiler. Önerilen modelde 10 dakika adımla, 1 günlük veri ile 3 günlük için tahminleme yapılmış ve elde edilen sonuçlar,

yapay sinir ağı tabanlı 4 modelle karşılaştırılmıştır. Önerilen modelin rüzgar hızını ve rüzgar gücünü tahmin etmede daha iyi doğruluk sağladığını bildirmişlerdir.

Zhang ve ark. (2017) veri işleme işleminin önemini vurgulayarak rüzgar hızı tahminlemede, olumsuz olmayan kısıtlama teorisi (NNCT, no negative constraint theory), kaotik yerel arama ile çiçek tozlaşma algoritması (CLSFPA, the flower pollination algorithm with chaotic local search), uyarlanabilir gürültülü bütünleşik ampirik mod ayrıştırma (CEEMDAN, Complete Ensemble Empirical Mode Decomposition Adaptive Noise) ve beş farklı sinir ağını kullanarak hibrit bir model oluşturmuşlardır. Önerilen model, ARIMA modeli ile karşılaştırmayı tercih etmişler ve en iyi performansı gösterdiğini belirtmişlerdir.

Bokde ve ark. (2018), farklılık ve ayrıştırma prensiplerinin kullanımına dayanan kısa rüzgar gücü tahmini için iki ön işleme yöntemleri önerilmiştir. Farklılaşma yöntemi verileri farklılaştırır ve daha sonra PSF yöntemiyle tahmin eder. Diferansiyel PSF (DPSF) modeli olarak adlandırılır. Ayrıştırma yaklaşımında, EEMD – Desen Dizisi Tabanlı Tahmin (EEMD-PSF) modeli kullanılmıştır. Hem ayrıştırma (EEMD-PSF) modeli hem de farklılık gösteren (DPSF) modelleri, tahmin hatası karşılaştırması açısından diğer modellerden neredeyse eşit derecede daha iyi performans gösterir.

He ve ark. (2018), kısa süreli rüzgar hızı tahmini için üç modül (ön işleme, kümeleme ve tahmin) içeren hibrit bir tahmin sistemi önermişlerdir. Veri ön işlemede, ham veri serisi içindeki gürültünün etkisini azaltmak ve özellikleri çıkarmada elverişli bir seri elde etmek için yüksek frekanslı sinyallerin kaldırılmasında ayrıştırma tekniği olan Toplu Ampirik Mod Ayrıştırma (EEMD, Ensemble empirical mode decomposition)'yı, veri kümeleme modülünde rüzgar hızı verileri içindeki benzerlik özelliğini çıkarmak için Çekirdek Bazlı Bulanık C-Aracı Kümeleme (KFCM, kernel-based fuzzy c-means clustering) algoritmasını ve tahmin modülünde ise Dalgacık Sinir Ağ'ı (WNN, wavelet neural network) kullanmışlardır. Mevsimsel veri seti üzerinde yapılan deneylerin bahsedilen hibrit modelin (EKW) yaygın olarak kullanılan diğer modellerden daha iyi performans gösterdiğini bildirmişlerdir.



Liu ve ark. (2018) çalışmalarında, WPD (Dalgacık Paket Ayırıştırma), CEEMDAN (Bütünleşik Grup Ampirik Mod Ayırıştırma) ve YSA (Yapay Sinir Ağı) kullanılarak çok adımlı rüzgar hızı tahmin için yeni bir karma çerçeve önerilmişlerdir. Ayrıca geri yayılma sinir ağını (BPNN, Back Propagation Neural Network) modeli, RBF (Radyal Temel Fonksiyon Sinir Ağı) modeli ve GRNN (Genel Regresyon Sinir Ağı) modeli olmak üzere üç tip YSA modeli kullanmışlardır. Sunulan çerçevenin tahmin performansını araştırmak için ayrıştırılmış rüzgar hızı serisi, BPNN modeli, WPD-BPNN modeli, WPD-CEEMDAN-BPNN modeli, RBF modeli, WPD-RBF modeli, WPD-CEEMDAN-RBF modeli, GRNN modeli, WPD-GRNN modeli ve WPD-CEEMDAN-GRNN modeli gibi dokuz modelle karşılaştırılmıştır. Sonuçlarda önerilen WPD-CEEMDAN-YSA modelinin, üç aşamalı tahminlerde yer alan ilgili YSA modellerinden ve WPD-YSA modellerinden daha iyi performansa sahip olduğunu göstermişlerdir.

Sun ve ark. (2018) rüzgar hızı tahmininin doğruluğunu arttırmak için hızlı topluluk ampirik mod ayrışması, örnek entropi, faz alanı rekonstrüksiyonu ve iki gizli katmana sahip geri yayılma sinir ağını (BPNN, Back Propagation Neural Network) içeren yenilikçi bir hibrit rüzgar hızı tahmin modeli önermişlerdir. Kıyaslama modelleriyle karşılaştırıldığında, önerilen model kısa vadeli rüzgar hızı tahmininde daha iyi bir performans gösterdiğini bildirmişlerdir.

Tian ve ark. (2018), hibrit veri ön işleme stratejisine ve çok amaçlı saten çardak kuşu optimizasyon (MOSBO) adı verilen yeni bir yonteme dayanan rüzgar hızı tahminleri için bir optimizasyon yöntemi geliştirmişlerdir. Yöntem veri ön işleme, optimizasyon, tahmin ve değerlendirme olmak üzere 4 modülden oluşmaktadır. Çin'deki iki rüzgar santralinden toplanan sekiz rüzgar hızı veri setine dayalı tahmin sisteminin, bir rüzgar çiftliğinde etkin ve verimli olduğunu göstermek için tasarlamışlardır. Çalışmalar farklı veri ön işleme yaklaşımlarına (CEEMD, SE, VMD) sahip hibrit modelden, farklı optimizasyon algoritmalarına (MOP, MOSBO) sahip hibrit tahmin modeline, geleneksel modeller ve yapay sinir ağlarını içeren bireysel tahmin modellerine (ENN) ve yüksek dereceli ve prestijli olarak yayınlanan en son araştırma bulgularına (MAPE, MAE, RMSE, IA, DA, FE) dayanmaktadır. Bu dört karşılaştırmalı modelin sonuçlarını kapsamlı bir şekilde incelendiğinde, test edilen tüm vakalarda önerilen öngörü modelinin ortalama MAPE

performans geliştirme yüzdeleri %56,27, %10,36, %82,6 ve %59,10'dur. Deney sonuçlarında, önerilen sistemin, rüzgar hızı tahmini için diğer tüm karşılaştırmalı modellerden daha iyi performans gösterdiğini bildirmişlerdir.

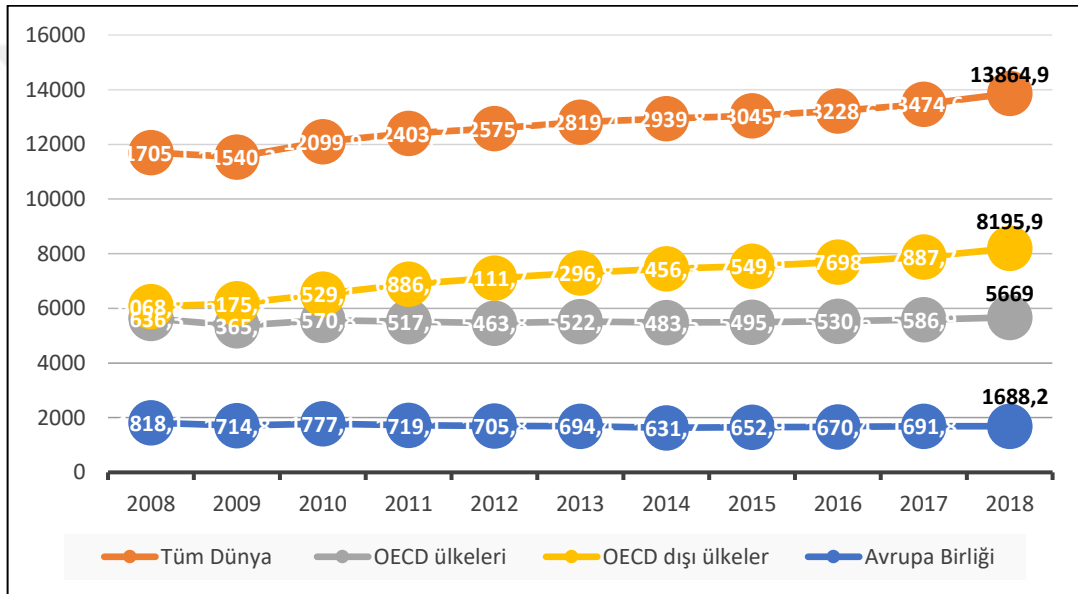
Qu ve ark. (2019) çalışmalarında yeni bir karma ayrıştırma tekniği ile geliştirilen çiçek tozu algoritması (FPA, Flower-Pollination Algorithm) ve geri yayılım sinir ağı (BPNN) algoritması kullanmışlardır. Karma ayrıştırma tekniğinde ise CEEMDAN+EWT'yi tercih etmişlerdir. Önerilen modelin, çok adımlı rüzgar hızı tahmininde referans alınan diğer modellerden çok daha iyi performans sergilediğini göstermişlerdir.

Qian ve ark. (2019) yaptıkları çalışmada rüzgar hızı tahmin doğruluğunu arttırmak için kullanılan ayrıştırma yöntemlerini incelemişlerdir. Ayrıştırma tabanlı modeller, önce rüzgar hızı / güç zaman serilerini nispeten daha sabit alt kümelere ayıran ve daha sonra her alt küme için tahmin modelleri oluşturan hibrit model ailesidir. Ayrıştırma tabanlı hibrit tahmin modellerini, dalgacık tabanlı modellere, EMD tabanlı modellere ve diğer ayrıştırma bazlı modellere göre sınıflandırmışlardır.

### 3. DÜNYADA ve TÜRKİYE’DE ENERJİ DURUMU


#### 3.1 Dünyada Birincil Enerji ve Rüzgar Enerjisi Potansiyeli

Dünyadaki enerji tüketim miktarının yıllara göre MTEP (Milyon ton eşdeğer petrol) olarak değişimi Şekil 3.1’de göstermektedir. Görüleceği üzere enerji tüketiminde artan bir eğilim vardır. Özellikle gelişmekte olan OECD-dışı ülkelerde ciddi bir artış gözlenmektedir (Koç ve Şenel, 2013).



Şekil 3.1. Dünyada Yıllara göre Birincil Enerji Kullanımı (Anonim, 2019a)


Yeryüzünde varolan enerjinin büyük bir kısmı birincil enerji kaynaklarına dayanmaktadır. 2018 yılı verilerine göre dünyada birincil enerji kullanım miktarı 13.864,9 MTEP olarak gerçekleşmiştir. Şekil 3.2’de birincil enerji kullanımında en büyük paya sahip olan kaynakların sırasıyla; petrol (%33.6), kömür (%27.2) ve doğal gaz (%23.9) olduğu görülmektedir. Şekilde yer alan yenilenebilir enerji kaynaklarını ise rüzgar, güneş, biyoyakıt ve jeotermal enerji kaynakları temsil etmektedir (Şenkal, 2014).



Şekil 1.2. Dünyada 2018 Yılı Birincil Enerji Kullanımı (Anonim, 2019a)


Dünya birincil enerji kullanımında ağırlığı olan fosil yakıt rezervlerinin sınırlı olması ve bu kaynakların kullanımı ile ortaya çıkan küresel ısınma sorunu, dünya genelinde artan çevre duyarlılığı, yenilenebilir enerji kaynaklarına olan önemi giderek artırmaktadır. Yenilenebilir enerji kaynaklarından rüzgar, sahip olduğu avantajları nedeniyle ön plana çıkmaktadır. Bu sebeple bilhassa öncü ülkeler, arz güvenliğinin oluşturulması ve dışa olan bağımlılığın azaltılması için rüzgar enerji üretimini ve kullanımını her geçen gün ciddi oranlarda desteklemektedirler. Dünyada elektrik enerjisi tüketimi, 2040 yılına gelindiğinde rüzgar enerjisi %20'lik kısmı karşılayacağı tahmin edilmektedir (Bayraç, 2011). Yenilenebilir enerji kaynaklarından biri olan rüzgar enerjisi, her geçen gün enerji sektöründeki payını arttırmaktadır.

Rüzgar enerjisi çevrim sistemlerinin hem karada (onshore) hem de deniz üstünde (offshore) de tesis edilmesi mümkündür (Şenkal, 2014). Bu kapsamda dünya üzerinde yıllara göre rüzgar enerjisine ait hem karasal hem de deniz üstü toplam kurulu güç dağılımı Şekil 3.3'de gösterilmektedir.



Şekil 3.3. Dünyada toplam rüzgar enerji kurulumlarının yıllara göre gelişimi (Anonim, 2019b)

Küresel rüzgar enerji konseyinin (GWEC) raporuna göre 2018 yılında rüzgar enerjisinde 51.3 GW kurulu güce ulaşılmıştır. Böylelikle toplam kurulu güç 591 GW ulaşmıştır. Karasal rüzgar pazarındaki yeni tesisler 46.8 GW'a (Şekil 3.4.a) ulaşırken, küresel deniz üstü pazarı 4.5 GW'a (Şekil 3.4.b) ulaşarak küresel pazardaki payını %8'e çıkarmıştır.



Şekil 3.4. a) 2018 Karasal yeni tesisler

b) 2018 Deniz üstünde yeni tesisler


Çin karasal kurulu rüzgar gücü pazarında, 2018'de 21,2 GW kurulu güç ile 2008'den bu yana lider pazar konumundadır. 2018'in sonunda toplam 206 GW kurulu gücü olan Çin, 200 GW toplam kurulu güce ulaşan ilk ülke olmuş ve bunu beş yıllık planlarının (2016-2020 sonunda hedef 200 GW) daha ikinci yılında başarmışlardır. Yenilenebilir enerji

kaynaklarından olan rüzgar enerjisinin entegrasyonu ve doğrudan sübvansiyonlardan uzaklaşılması için pazar mekanizmaları konusunda daha fazla ilerleme beklenmektedir. 2018'deki ikinci en büyük pazar, 7.6 GW yeni karasal kurulum ile toplam 96 GW karasal kurulumu olan ABD'dir. 2020 - 2021 yılına kadar kredi teşviklerinin, yeni tesisler için ana itici güç olarak kalacağı belirtilmiştir. Çin ve ABD'den sonra, 2018'deki rüzgar kurulu gücü açısından ilk beş sıralamanın içerisinde yer alan ülkeler Almanya (2.4 GW), Hindistan (2.2 GW) ve Brezilya (1.9 GW) olmuştur (Anonim, 2019b).

Verilen rakamlar incelendiğinde elektrik üretiminde özellikle rüzgar öncülüğünde yenilenebilir enerji kaynaklarının daha çok seçildikleri görülmektedir. Dünyada hidrolik yerine rüzgar enerjisi sistemlerinin tercih edilerek elektrik üretilmesine yönelik hamleler yapılmaktadır. Dolayısıyla gelecek dönemlerde yapılacak çalışmalarla maliyetler hızlı bir biçimde düşürülecek ve modern yenilenebilir kaynaklar olarak tanımlanan rüzgar enerjisi ile elektrik üretimi daha da yaygınlaştırılacaktır (Karagöl ve Kavaz, 2017).


### 3.2 Türkiye'de Birincil Enerji ve Rüzgar Enerjisi Potansiyeli

Türkiye Cumhuriyeti Enerji ve Tabii Kaynaklar Bakanlığının resmi sitesinde yayınlanan Türkiye'nin 2018 yılında elektrik üretimi Şekil 3.5'te gösterilmektedir. Buna göre üretimin %37.3'ü kömürden, %29.8'i doğal gazdan, %19.8'i hidrolik enerjiden, %6.6'sı rüzgardan, %2.6'sı güneşten, %2.5'i jeotermal enerjiden ve %1.4'ü diğer kaynaklardan elde edilmektedir (Anonim, 2019c).



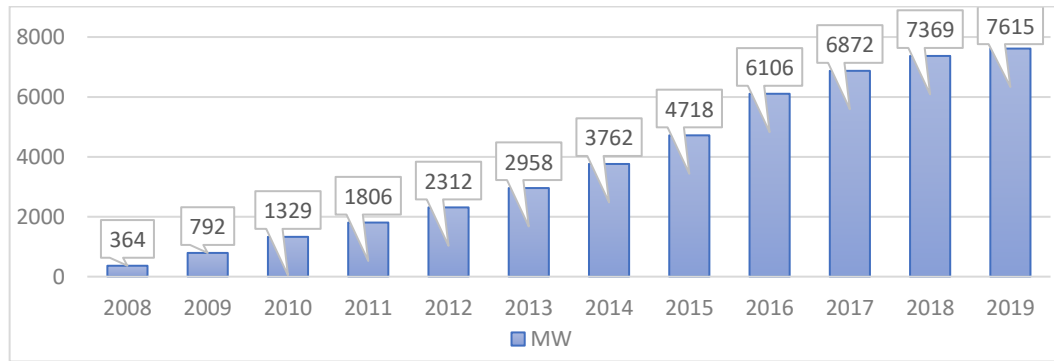
Şekil 3.5. Kaynak bazlı 2018 yılı elektrik üretimi (Anonim, 2019c)

Türkiye perspektifinden bakıldığında fosil yakıtların tüm kaynaklar içerisinde oldukça yüksek bir orana sahip olduğu görülmektedir. 2019 yılı ilk yarısı itibarıyla, Şekil 3.6’da görüldüğü gibi ülkemiz toplam kurulu gücü 90.421 MW'a ulaşmıştır (Anonim, 2019c).



Şekil 3.6. 2019 yılı ilk yarısı itibarıyla kurulu gücümüz (Anonim, 2019c)

Türkiye'nin rüzgar türbin kurulu güç kapasitesi 7.615 MW olup 2018 yılında rüzgar santrallerinden üretilen elektrik enerjisi 4.726 milyar kWh olarak gerçekleşmiştir. Şekil 3.7’de 1998–2019 yılları arasında Türkiye’de toplam kurulu rüzgar gücü kapasitesi gösterilmiştir (Anonim, 2012).



Şekil 3.7. Türkiye’de toplam kurulu rüzgar gücü kapasitesi (Anonim, 2012)

Türkiye'nin enerjide dışa bağımlılığının azaltılması için yenilenebilir enerji kaynaklarının kullanılması 2023 Milli Enerji Politikamızda da yer almaktadır. Bu sebeple Türkiye’de yenilenebilir kaynaklarından enerji üretimini desteklemek üzere, 4628 sayılı Elektrik Piyasası Kanunu ile 5346 sayılı Yenilenebilir Enerji Kaynaklarının (YEK)

Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun'lar meclisimizden geçmiştir (Bayraç, 2011).

Bununla birlikte ülkemizin sahip olduğu diğer yenilenebilir enerji kaynakları (hidrolik, güneş, jeotermal, biyokütle ve rüzgar) potansiyellerinin genel değerlendirilmesi aşağıda özetlenmiştir.

**Hidrolik Enerji:** Hidrolik enerji akarsuyun kazandığı kinetik veya potansiyel enerjinin elektrik enerjisine dönüştürülmesiyle elde edilen bir enerji çeşididir. Bununla birlikte hidrolik enerjisi temiz bir yenilenebilir enerji kaynağı olması hasebiyle gerek sera gazı salınımında gerekse fosil yakıt bağımlılığını önleyici etkiye sahiptir. Teoride Türkiye'nin hidroelektrik potansiyeli (bütün kaynaklar %100 verimle değerlendirildiğinde) 433 milyar kWh, teknik olarak değerlendirildiğinde potansiyeli 216 milyar kWh ve ekonomik potansiyeli ise 140 milyar kWh/yıl olduğu hesaplanmaktadır. Türkiye 2023 gelecek hedefinde hidrolik enerji kurulu güç kapasitesini 36 bin MW seviyesine çıkarılması vardır. Türkiye'nin coğrafik konum olarak hidrolik enerji bakımından çok önemli bir potansiyeli vardır (Karagöl ve Kavaz, 2017).

**Güneş Enerjisi:** Türkiye bulunduğu coğrafi konumundan dolayı güneş enerjisinde önemli bir kapasiteye sahiptir. Türkiye'nin güneşlenme süreleri yıl içerisinde değişiklik gösterse de toplamda yaklaşık 2 bin 738 saattir. Günlük ortalama 7,5 saatlik güneşlenme süresine sahip olan Türkiye'nin, Almanya'dan %60 daha fazla güneşten faydalana bilmektedir. Türkiye'nin güneşten elektrik üretim potansiyeli, yapılan yapılan çalışmalar neticesinde en az 500 bin MW olarak tahmin edilmektedir (Bayraktar, 2016). Güneş enerjisinden teknik olarak elektrik üretim potansiyeli 189 GWh/yıl olan Türkiye, bu rakamlarla avrupada İspanya ve Fransa'dan yaklaşık %30 daha fazla potansiyele sahiptir. Türkiye'nin yüksek bir potansiyele sahip olmasının ardındaki sebep yeryüzünde sahip olduğu coğrafi konumudur. Türkiye'de yakın zamana kadar güneş enerjisinden çoğunlukla binaların çatılarında su ısıtma amacıyla kullanılırken, 2010 yılından itibaren güneş paneli sistemlerin kullanımında bir gelişme gözlemlenmiştir (Karagöl ve Kavaz, 2017).




**Jeotermal Enerji:** Yerkürenin birçok bölgesinde sıcak su, gaz ve buhardan elde edilen bir enerji türü olan jeotermal enerji temiz bir yenilenebilir enerji kaynağıdır. Türkiye coğrafi ve jeopolitik konumu nedeniyle jeotermal enerjinin yaygın olarak bulunduğu bir ülkedir. Maden Tetkik ve Arama Genel Müdürlüğü'nün (MTA) yaptığı incelemelere göre Türkiye'de, Elektrik üretimine uygun saha sayısı 2002 yılında 16 iken 2018 yılında 25 adede çıkmıştır. Elektrik üretiminde kurulu güç 2002 yılında 15 MWe iken 2019 yılında 1.304 MWe olmuş ve %8.600 artış olmuştur. Ülke görünür ısı kapasitesinde ise 2002 yılında 3 bin MWt'dan 2019 yılında 35.500 MWt'ya (özel sektörle birlikte) çıkmış ve %1.083 artış sağlamıştır (Anonim, 2019d).

Türkiye jeotermal ısı enerjisi potansiyeli yönüyle dünyada Çin'den sonra ikinci sırada yer almaktadır. Diğer bir ifadeyle Türkiye jeotermal enerjide potansiyel ve kapasite artışı bakımından dünyada önemli bir yere sahiptir. Bunun yanında 2007 yılında çıkarılan "Jeotermal Kaynaklar ve Doğal Mineralli Sular Kanunu" ile jeotermal alanında ilk ciddi kanuni altyapı çalışmaları başlatılmış ve bu nedenle jeotermal enerji ile ilgili yatırım yapanların sayısında önemli bir artış meydana gelmiştir (Karagöl ve Kavaz, 2017).

**Biyokütle Enerjisi:** Türkiye'de biyokütle enerjisinin kullanımı genel olarak ısınma ve pişirme gibi geleneksel tekniklerden oluşmaktadır. Ülkemizde yüksek potansiyeli olan biyokütle enerjisi diğer yenilenebilir enerji türlerine göre kullanım açısından geri plandadır. 2019 yılı ilk altı ayında Türkiye'nin biyokütle enerjisi kurulu gücü yaklaşık 1.356,3 MW seviyelerinde bulunmaktadır. Bu bilgiler ışığında 2023 hedefi olarak 2 bin MW olarak belirlenen biyokütleye dayalı enerji üretim miktarına ulaşmak için çalışmalar devam etmektedir. Bilhassa orman bakımından güçlü olan kıyı kesimlerinden elde edilebilecek toplam atık miktarı yaklaşık olarak 4.8 milyon ton yani 1.5 MTEP'dir. Yine ormanlarda kurulabilecek gazlaştırma tesisi kapasitesi ise 600 MW civarındadır. Buna ilave olarak tarla ve bahçelerdeki toplam kullanılabilir atık miktarı 15.3 milyon ton ve bu miktarın ısı değeri ise 303.2 PJ yani 7.24 MTEP'e eşittir. Buna rağmen Türkiye'de modern teknikler kullanacak biyokütle enerjisi üretim tesisleri gelişme aşamasındadır (Karagöl ve Kavaz, 2017).

**Rüzgar Enerji:** Türkiye’de yenilenebilir enerji kaynaklarından rüzgar enerjisine olan yönelimler ülkenin yüksek rüzgar enerjisi potansiyelinin ortaya konulmasıyla önem kazanırken, rüzgarın, Türkiye’nin gelecekteki enerji üretiminde önemli bir rol oynayacağı söylenebilir (Yanıktepe ve ark., 2013). Türkiye genelinde rüzgar güçleri dikkate alındığında bölgeler arasında fiziki ve coğrafi konumlarına göre farklılıklar gözlenir. Rüzgar enerjisi yatırımlarında ön projede yapılan ilk çalışmaları potansiyel belirleme oluşturmaktadır. Ve bu Türkiye’nin rüzgar enerjisi potansiyelini belirleme çalışmaları ile Meteoroloji Genel Müdürlüğü tarafından, Türkiye’ye eşit olarak dağılmış 45 farklı meteorolojik istasyona ait, 10 yıl süreyle ölçülmüş, saatlik rüzgar hızları kullanılarak “Türkiye Rüzgar Atlası” oluşturulmuştur. Elde edilen verilere göre yerden 50 metre yükseklikte, yıllık ortalama rüzgar hızının 7 m/s ve üzerinde olduğu bölgelere ait güç yoğunlukları hesaplanmış ve kullanılabilir alanlar dikkate alınarak Türkiye’nin rüzgar enerjisi potansiyeli belirlenmiştir. Şekil 3.8’de görüldüğü gibi toplam kurulabilecek rüzgar gücü kapasitesi 47.849 MW olarak belirlenirken, bu miktarın 10 bin MW’lık kısmı deniz üstü alanlar, 37.836 MW’lık kısmı ise kara üstü alanlar için hesaplanmıştır (Soğukpınar ve Bozkurt, 2014).



Şekil 3.8. Türkiye rüzgar enerjisi potansiyeli (Çalışkan, 2011)

Türkiye Rüzgar Atlası’na göre 50 metre yükseklikte ve yerleşim yerlerinin dışında kalan alanlar için yapılan hesaplamalarda; Marmara, Batı Karadeniz ve Doğu Akdeniz kıyılarında yıllık ortalama rüzgar hızının 6 - 7 m/s aralığında olduğu görülürken, iç bölgelerde 4.5 – 5 m/s aralığına düştüğü görülmektedir. Kuzeybatı Ege kıyılarında ise yıllık ortalama rüzgar hızı 7 – 8,5 m/s aralığına çıkarken, Ege Bölgesi’nin iç kesimlerinde 6.5 - 7 m/s aralığında bir ortalama olduğu belirtilmiştir (Yanıktepe ve ark., 2013). Genel

olarak Türkiye'deki yedi coğrafi bölgenin değerlendirilmesiyle ise rüzgar enerjisi sistemleri için en uygun bölgelerin Marmara, Ege ve Güneydoğu Anadolu bölgeleri olduğu sonucu çıkartılırken, Çanakkale, İzmir, Balıkesir, Hatay ve İstanbul'un rüzgar potansiyeli en yüksek iller olduğu belirtilmektedir (İlkiliç, 2012).



#### 4. RÜZGAR GÜCÜ ve RÜZGAR HIZI TAHMİNLEMESİ

Rüzgar türbinleri, rüzgardaki kinetik enerjiyi, önce mekanik enerjiye sonra da elektrik enerjisine dönüştüren sistemlerdir. Rüzgarı enerjiye dönüştürmek için öncelikle potansiyel rüzgar gücü belirlenmelidir. Rüzgar gücü, hava yoğunluğu ile doğrusal olarak değişmektedir. Uluslararası standart atmosfer (ISA) koşullarında (deniz seviyesinde +15°C sıcaklıkta ve 1.013,25 mb atmosfer basıncında) havanın yoğunluğu 1.225 kg/m<sup>3</sup>'tür. Eşitlik 4.1'de ideal gaz denklemi gösterilmiştir. (Emeksiz, 2014)

$$P.V = n.R.T \quad (4.1)$$

En temel haliyle hava yoğunluğu eşitlik 4.2'de verilmiştir.

$$P = \frac{P.MW.10^{-3}}{R.t} \quad (4.2)$$

4.2 eşitliğinde P mutlak basınç (atm), V hacim (m<sup>3</sup>), n mol sayısı (mol), R ideal gaz sabiti, T kelvin cinsinden mutlak sıcaklık, MW havanın moleküler ağırlığı olarak ifade edilmektedir.

Rüzgar türbinlerinin ürettiği güç, türbin rotorunun süpürdüğü alan ile doğru orantılıdır. Yatay eksenli türbin için rotorun süpürdüğü alan eşitlik 4.3'te gösterilmiştir. 4.3 eşitliğinde R metre cinsinden kanat çapını ifade etmektedir. Yatay eksenli türbinlerde süpürme alanı kanat çapının karesi ile orantılıdır (Patel, 2006).

$$A = \frac{\pi}{4R^2} \quad (4.3)$$

Rüzgar enerjisinin denklemi, kinetik enerji denklemine benzemektedir. Rüzgar enerjisinde kinetik enerji gibi güç, rüzgar hızına ve havanın kütlesine dolaylı olarak da havanın yoğunluğuna bağlıdır. m kütlesine sahip V<sub>1</sub> hızı ile hareket eden havanın kinetik enerjisi eşitlik 4.4'de verilmiştir.

$$E_k = \frac{1}{2} \cdot m \cdot v_1^2 \quad (\text{Nm}) \quad (4.4)$$

Hareket halindeki hava kütlesi türbin rotorunun süpürdüğü alana (A) çarptığında hava kütlesindeki kinetik enerjinin belirli bir kısmı frenlenir. Frenlenen enerji türbin kanatlarının çalıştırılmasında kullanılır (Çetin, 2006). Türbin kanatlarına çarpan  $P_h$  yoğunluğundaki havanın kütleli debisi eşitlik 4.5’de gösterilmiştir.

$$m = p_h \cdot v_1 \cdot A \quad (\text{kg/s}) \quad (4.5)$$


Birim zamanda yapılan iş, güç olarak tanımlandığında, iş yapabilme yeteneği ( $p_r$ ), eşitlik 4.6’da gösterilmiştir.

$$p_r = \frac{\frac{1}{2} \cdot m \cdot v_1^2}{t} \quad (\text{Nm/s}) \quad (4.6)$$

$dm / dt = m$  şeklinde ifade edilip, m yerine 4.5’deki eşitlik yazıldığında rüzgardan elde edilebilecek teorik güç eşitlik 4.7’deki gibi olmaktadır.

$$p_r = \frac{1}{2} \cdot p_h \cdot A \cdot v_1^3 \quad (\text{W}) \quad (4.7)$$

Rüzgar türbinlerinde rüzgar gücünün performansı rüzgar hızının küpüyle ve rotor süpürme alanıyla doğru orantılı olarak artmaktadır. Bir rüzgar türbinin rüzgar gücünden en fazla %59 oranında faydalanır. Bu teoreme Betz teoremi denir (Emeksiz, 2014). Betz teoremi ile ilgili olarak, rüzgar pervanesinden geçen havanın enerji hareketi Şekil 4.1’de görülmektedir.



Şekil 4.1. Betz kanunu (Özpinar, 2007).

Rüzgar pervanesinden geçen havanın enerji dengesi;

$$E_{kt} = E_{k_1} - E_{k_2} \quad [\text{Nm}] \quad (4.8)$$

olarak tanımlanabilir. Hareket halindeki rüzgarın taşıdığı kinetik enerji, kinetik enerjinin tanımına göre düzenlenecek olursa 4.8 numaralı eşitlik, aşağıdaki şekilde yazılabilir:

$$E_{kt} = \frac{1}{2} \cdot m \cdot (v_1^2 - v_2^2) \quad [\text{Nm}] \quad (4.9)$$

Güç; birim zamanda yapılan iş olduğuna göre, türbinden elde edilecek güç;

$$P_t = \frac{E_{kt}}{t} = \left(\frac{1}{2}\right) \cdot \left(\frac{dm}{dt}\right) \cdot (v_1^2 - v_2^2) \quad [\text{Nm/s}] \quad (4.10)$$

şeklinde yazılır. Burada;  $dm/dt$ ,  $\dot{m}$  ile ifade edilirse, türbinden elde edilecek güç;

$$P_t = \frac{E_{kt}}{t} = \left(\frac{1}{2}\right) \cdot \dot{m} \cdot (v_1^2 - v_2^2) \quad [\text{W}] \quad (4.11)$$

şeklini alır. Rüzgarın türbin kanatlarında yapacağı iş, aynı zamanda rüzgar tarafından kanatlara uygulanan birim zamandaki basınca bağlıdır:

$$P_t = S \cdot V \quad [\text{W}] \quad (4.12)$$

Rüzgarın, türbin kanatlarına yapacağı basınç ise;

$$S = \dot{m} \cdot (v_1 - v_2) \quad [\text{kgm/s}^2] \quad (4.13)$$

olarak ifade edilebilir. 4.11 ve 4.12 numaralı denklemler birbirine eşitlenip, 4.13'de yerine yazılırsa;

$$\dot{m} \cdot v \cdot (v_1 - v_2) = \frac{1}{2} \cdot \dot{m} \cdot (v_1^2 - v_2^2) \quad (4.14)$$

elde edilir. Buradan;

$$v = \frac{1}{2} \cdot (v_1 + v_2) \quad [\text{m/s}] \quad (4.15)$$

bir sonuç elde edilir. Bu durumda, türbine gelen rüzgar hızının, kanatların önündeki ve arkasındaki rüzgar hızlarının ortalaması olduğu sonucu ortaya çıkmaktadır. 4.5 numaralı eşitlik kullanılarak, türbinden geçen havanın kütleli debisi ( $\dot{m}$ ), 4.11'de yerine yazılırsa;

$$P_t = \left(\frac{1}{2}\right) \cdot \rho_h \cdot v \cdot A \cdot (v_1^2 - v_2^2) \quad [\text{W}] \quad (4.16)$$

ifade elde edilir. 4.15 numaralı eşitlik 4.16'de yerine yazılırsa;

$$P_t = \left(\frac{1}{4}\right) \cdot \rho_h \cdot A \cdot (v_1 + v_2)(v_1^2 - v_2^2) \quad [\text{W}] \quad (4.17)$$

ifadesi elde edilir.  $P_t$  ve  $P_r$  değerleri birbirine oranlandığında;

$$C_p = \left(\frac{P_t}{P_r}\right) = \frac{1}{2} \left(1 - \left(\frac{v_2}{v_1}\right)^2\right) \left(1 + \left(\frac{v_2}{v_1}\right)\right) \quad (4.18)$$

türbin verimi olan  $C_p$  elde edilir.  $\frac{v_2}{v_1} = n$  ile tanımlanırsa;

$$C_p = \frac{1}{2}(1 - n^2)(1 + n) \quad (4.19)$$

şeklinde verim katsayısı fonksiyonu elde edilir. Fonksiyonun türevini alınıp sıfıra eşitlendiğinde,  $C_p$  'yi maksimum yapan  $n$  değeri  $1/3$  olarak bulunur. Bunun anlamı,  $C_p$  'nin maksimum olması için kanatların, rüzgarın türbin giriş hızı, türbinden çıkış hızının 3 katı olacak şekilde dizayn edilmesi gerektiğini göstermektedir. Bu durumda türbinden elde edilecek maksimum verim, 0,5926 olacaktır. Pratikte bu oran yaklaşık %45 olabilmektedir (Çetin, 2001).

İnsanlar varoluşlarından beri çeşitli tahminler yapmaktadırlar. Belirlenen bir hedef için tahminde bulunmak, karar almada, ekonomik ve iktisadi alanlarında bir temel teşkil ettiği için çok önemlidir. Bununla birlikte, tahminler hedeflenen çalışma amacına uygun olarak uyarlandıysa önemlidir. Uygulamalarının kapsamını ve hedeflerini tanımlamak için, doğru tahmin yöntemleri geliştirilmelidir (Chatfield, 2002).

Özellikle rüzgar enerjisi tasarımlarında; altyapı imkanlarının bilinmesi, bölgenin rüzgar enerjisi potansiyelinin belirlenmesi, ilgili ölçümlerin yapılması ve rüzgar hızlarının tahmin yapılıyor olması çok önemlidir. Rüzgar enerjisinin kullanılabilmesi rüzgar rejiminin doğru modellenmesine ve karakteristiklerin doğru belirlenmesine bağlıdır (Köse ve ark., 2014). Lakin rüzgar enerjisinin, rüzgar hızına bağlı olarak sürekli değişimi, şebekelerde üretim / tüketim dengesizliğine neden olabilmektedir. Bu dengesizlikler sonucunda gerilim ve frekans değişimi gibi ortaya çıkabilecek olan önemli sorunların önüne geçebilmek için şebekedeki elektrik üretimi ve tüketimi arasındaki denge sürekli olarak korunmalıdır (Şenkal, 2014). Ayrıca rüzgar gücü tahminlerinin geliştirilmesi ile önemli ekonomik ve teknik avantajlar elde edileceği de bildirilmektedir (Soman ve ark., 2010).

Bu nedenle rüzgar hızı tahminlemesi alanında yapılan çalışmalar, rüzgar tahminlerinin yüksek doğrulukla yapılmasının, iletim sistemlerine bağlanma kriterleri, çeşitli filtreleme yöntemleri ve uygun teknolojiye sahip türbinlerin kullanılması ile giderilebileceğini işaret etmektedir (Uygun ve Eker, 2009).



Rüzgar santralının gerçek çıkış gücünü doğru zamanda yakalayabilmek ve elektrik şebekesinin dağıtım planını planlamak için çıkış gücünü doğru bir şekilde hesaplanması çok önemlidir (An ve ark., 2012). Rüzgar gücü hesabı için en çok kullanılan yöntem, rüzgar hızının tahminiyle ve güç eğrilerinden yararlanarak güç değerlerinin hesaplanmasıdır. Dolayısıyla rüzgar hızının tahmin edilebilmesi ekonomik açıdan oldukça önemlidir. Çünkü üreticiler belirli bir üretim maliyetindeki enerji miktarları hesaplamalarını en az bir gün önceden bildirmektedirler (Tasçıkaraoğlu ve Uzunoğlu, 2011). Aksi takdirde hatalı bildirimler neticesinde fazla ya da eksik enerji için cezalar ödenmesi gerekmektedir (Şenkal, 2014).

Rüzgar enerjisi tahminlerinin yapılmasıyla:

- Güç sisteminin planlanması
- Rüzgar salınımlarını kompanze etmek için rezerv planlama
- Yedek tutma miktarını planlama
- Bakım ve onarımları planlama
- Koruyucu bakım yapma
- Elektrik piyasasına teklif verme
- Her türlü ortalama rüzgarlı bölgelerin değerlendirilmesine olanak tanıma
- Rüzgar enerjisinin sistemdeki oranını artırma gibi faydalar sağlanır (Akmador ve ark., 2009).

#### **4.1 Rüzgar Hızı Tahminlerinin Sınıflandırılması**

Rüzgar enerjisi üretiminde birden çok problemin çözümü için çeşitli tahmin sürelerinin ve yöntemlerinin değişik amaçlarla kullanıldığı görülmektedir (Smith ve ark., 2009). Rüzgar enerjisi konusunda yapılan tahmin çalışmaları temelde ikiye ayrılır. Birincisi rüzgar enerjisi potansiyeli hesaplamalarıdır. İkincisi ise zaman ekseni gelecekteki rüzgar hızını tahmin etmedir. Literatürde her iki alanda da çok sayıda çalışma vardır (Aoife ve ark., 2012; Türkyılmaz, 1997). Enerji Piyasası Düzenleme Kurulu (EPDK), elektrik iletim sistemlerinin Türkiye Elektrik İletim A.Ş. (TEİAŞ) tarafından verimli ve etkili olarak yönetilmesi için; rüzgar santrallerinden saatlik elektrik üretim tahminini bildirmelerini zorunlu hale getirmiştir. Rüzgar durağan ve doğrusal olmayan bir

parametre olduğu için, Rüzgar Enerjisi Üreticileri, üretecekleri elektrik enerjisi miktarını hesaplayabilmek için, 24 - 48 saatlik güvenilir rüzgar tahminlerine ihtiyaç duymaktadır (Dündar ve ark., 2011). Son dönemlerde bu alanda çok sayıda araştırma yapılmaktadır. Elektrik dağıtım şirketlerinin, güvenilir ve önceden tahmin edilebilir rüzgar enerji santrallerine (RES) ihtiyaçları vardır (Köse ve ark., 2014).

#### 4.1.1 Rüzgar hızı tahminlerinin zaman bazında sınıflandırılması

Gelecekteki rüzgar hızını tahmin etmek için zaman ekseninde yapılan çok fazla model ve çalışma vardır. Modellerin hepsi farklı özelliklere sahiptir. Örneğin bazıları kısa süreli tahminlemelerde iyi olmasına rağmen bazıları uzun süreli tahminlerde daha iyidir. Son zamanlarda matematiksel yöntemler ve yapay zekâdaki gelişmelerle birlikte birçok yeni metod ileri sürülmüştür (Şahin, 2001; Sfestos, 2000).

Tahminlerin zaman bazında sınıflandırmaları için belirlenen süreler, farklı kaynaklarda farklı uzunluklar dikkate alınarak incelendiği için bu sınıflandırmaların net sınırları olmadığı belirtilmektedir ve genel olarak Çizelge 4.1’de görüldüğü gibi dört grupta incelenmektedir (Monteiro ve ark., 2009).

Çizelge 4.1. Zaman bazında sınıflandırılması ve uygulamaları (Şenkal, 2014)

Zaman dilimi	Aralık	Uygulamalar
Çok kısa vadeli	Birkaç saniyeden 30 dakikaya kadar	<ul style="list-style-type: none"> <li>• Elektrik piyasası faiz oranları</li> <li>• Düzenletici eylemler</li> </ul>
Kısa vadeli	30 dakikadan 6 saate kadar	<ul style="list-style-type: none"> <li>• Ekonomik yük dağıtım planlaması</li> <li>• Yük arttırma/azaltma kararları</li> </ul>
Orta vadeli	6 saatten 1 güne kadar	<ul style="list-style-type: none"> <li>• Jeneratör çevrimiçi/çevrimdışı olma kararları</li> <li>• Bir sonraki gün ki elektrik piyasasında operasyonel güvenlik</li> </ul>
Uzun vadeli	1 günden 1 haftaya kadar (ve daha fazlası)	<ul style="list-style-type: none"> <li>• Birim taahhüt kararları</li> <li>• Rezerv gereklilik kararları</li> <li>• Optimal işletme maliyeti için bakım planlaması</li> </ul>

**Çok kısa süreli tahminler:** Birkaç saniyeden, 30 dakika zaman aralığında yapılan tahminlerdir. Türbinlerin aktif kontrolü, elektrik denge fiyatı ve düzenleme eylemleri için kullanılmaktadır (Cantürk, 2018). Bu tip tahminler genelde anlık tahminler olarak adlandırılmaktadır (Karık ve ark., 2017).

**Kısa süreli tahminler:** 30 dakikadan, 6 saate kadar olan zaman aralığında yapılan tahminlerdir. Ekonomik yük iletimi planlamasında, gün içi piyasası işlemlerinde, güç sisteminin yönetiminde ve sistem yönetimi için kullanılmaktadır (Köse ve ark., 2014).

**Orta süreli tahminler:** 6 saatten, 1 günlük zaman aralığında yapılan tahminlerdir. Gün sonu piyasası düzenlemeleri ve güç sisteminin yönetimi ile enerji ticareti için kullanılmaktadır (Cantürk, 2018). Bunlar, geleneksel elektrik santralleri kullanımına (ünite taahhüdü) karar vermek ve bu santrallerin planlanmasının optimize edilmesine yardımcı olabilmektedirler. Ticari uygulamasında, teklifler genel olarak  $d$ . günün sabahında,  $(d+1)$ . günü için 00:00–23:59 saatleri aralığına kadar gereklidir. Bu tahminler kısa süreli tahminler olarak adlandırılır (Karık ve ark., 2017).

**Uzun süreli tahminler:** 1 günden, 1 haftaya yada daha uzun süreler için yapılan tahminlerdir. Rüzgar enerji üretiminin şebekeye minimum maliyetle aktarılması kararlarını vermek için kullanılmaktadır (Jung ve Broadwater, 2014). Uzun süreli tahminler rüzgar santralleri, geleneksel elektrik üretim santralleri veya iletim hatlarının bakımlarının planlamasını yapmak için kullanılmaktadırlar. Çünkü büyük rüzgar santralleri veya deniz üstü santrallerin plansız bakımlarından kaynaklı cezai durum ortaya çıkarabileceğinden bakımlarının planlanması özel bir öneme sahiptir (Akmandor ve ark., 2009).

#### **4.1.2 Rüzgar hızı tahminlerinin yöntem bazında sınıflandırılması**

Dünyadaki rüzgar enerjisi tahmin uygulamaları incelendiğinde, genellikle devamlılık metodu, fiziksel yaklaşımlar, istatistiksel yaklaşımlar veya her iki yöntemin birlikte olduğu modellerin bir arada olduğu hibrit sistemler kullanılmaktadır (Dündar ve ark., 2011; Soman ve ark., 2010).

Literatürde rüzgar hızı tahmini için çeşitli yöntemler mevcuttur. Fiziksel yöntemler, uzun dönem rüzgar hızı tahmini için kabul görmesine rağmen anlık rüzgar enerjisi üretimi ve şebekeye entegrasyonunda gerekli olan ani ve kısa-dönem rüzgar hızı tahmininde yetersiz kalmaktadır. Bu manada doğrusal ve doğrusal olmayan çeşitli istatistiksel yöntemler ve hibrit yöntemler önerilmektedir (Filik ve Filik, 2017).

#### 4.1.3 Devamlılık metodu

Naive yöntem olarak da adlandırılan bir yöntemdir, Bu metotta, “ $t$ ” anındaki rüzgar hızının “ $t+\Delta t$ ” anındaki ile aynı olacağı varsayılmaktadır.  $t$  aralığındaki ve yakın zamanda gerçekleşecek sonraki tahmin basamaklarındaki ( $t+k$ ) rüzgar hızı ve buna bağlı olarak rüzgar üretim değerleri arasındaki ilişkilerine dayanılarak kullanılan bir tahmin yöntemidir (Şenkal, 2014). Meteorologlar tarafından Sayısal Hava Tahmini (SHT) sonuçlarının kıyaslanmaları için ikincil bir yöntem olarak geliştirilmiştir (Negnevitsky ve Potter, 2006). Naive tahmin yöntemi, elde edilen son verinin, sonradan elde edilecek değerler için de doğru olduğunu kabul etmektedir. Atmosferdeki değişim ölçeklerinin genellikle yavaş olması nedeniyle rüzgar hızı tahminlerinde iyi sonuç veren bir yöntem olduğu belirtilmektedir (Cantürk, 2018). Kısa ve çok kısa süreli tahminlerde de kullanılan fiziksel ve istatistiksel metotların birçoğundan daha basit ve başarılı bir yöntemdir, Naive yöntem, yapılan birçok tahminlerin karşılaştırılabilmesi ve sonuçların değerlendirilebilmesi için referans model olarak da kullanılmaktadır (Özdamar, 2001).

#### 4.1.4 Fiziksel yaklaşımlar

Fiziksel yaklaşımlar, atmosferde bulunan parametreleri kullanarak tahmin yapabilen yöntemlerdir (Soman ve ark., 2010). Fiziksel sistemler, ayrıntılı fiziksel tanımlamaların; etraftaki bitki örtüsü, yükseklik, sıcaklık, basınç, çevrede bulunan türbinlerin yerleşimi gibi koşulların belirlenmesi ile rüzgar hızı tahmini yapılmaktadır. Rüzgar hızı tahmininde fiziksel yaklaşımlardan biriside Sayısal Hava Tahmini (SHT)'dir. Sayısal hava tahmin modelleri karmaşık matematiksel modellerin çözümü için çalışır ve bu çözümler için girdi olarak SHT'den elde edilen veriler; sıcaklık, basınç, yüzey pürüzlülüğü ve engeller gibi hava verilerinin kullandığı bildirilmiştir (Şenkal, 2014).

SHT; modern rüzgar hızı tahmini sistemleri kısa süreli zaman dilimi içinde rüzgar hızı tahmininde de kullanır. Dolayısıyla, sonraki döneme ait tüm bilgiler özellikle rüzgar alanındaki beklenen gelişmeler SHT ile sağlanır. Günümüzde SHT verileri ulusal meteoroloji servisleri ile özel hava verisi sağlayıcı şirketlerin rüzgar tahmini için farklı SHT verileri sunmaktalar (Köse ve ark., 2014).

Yüksek matematiksel hesaplama yükünden dolayı sayısal hava tahmin modelleri süper bilgisayarlar üzerinde işlenmekte ve hesaplama sürelerinin çok zaman aldığı belirtilmektedir. Dolayısıyla 6 saatten daha kısa süreli tahminler için veri toplama ve yüksek maliyet sorunları ortaya çıkmasıyla bu yöntemin kısa süreli tahminlerden ziyade orta ve uzun süreli tahminler için uygun olduğu vurgulanmaktadır (Chang, 2013; Wu ve Hong, 2007).

#### **4.1.5 İstatistiksel yaklaşımlar**

İstatistiksel yaklaşımlar, zaman serisi modelleri ve yapay zeka tabanlı modeller olarak iki grupta incelenmektedir. Tahmin yapılabilmesi için bu yöntemlerde geçmişten gelen ölçülmüş verilere ihtiyaç vardır. İstatistiksel yaklaşım eldeki ölçüm verileri ile eğitilmiş yakın geçmişteki gerçek ile tahmin edilen rüzgar hızları arasındaki farkı kullanmaktadır (Potter ve Negnevitsky, 2006; Candy ve ark., 2009). Fiziksel yaklaşımlara nazaran kolay modellenebilmesi, maliyetinin düşük ve hızlı olması gibi sebeplerden dolayı istatistiksel yaklaşımların kısa süreli tahminler için daha uygun olduğu belirtilmektedir. İstatistiksel yaklaşımlarda tahmin edilecek sürenin çok kısa veya kısa olmaması tahmin performansının düşmesine sebep olmaktadır (Wu ve Hong, 2007).

Zaman serisi modellerine aynı zamanda istatistiksel öğrenme yöntemleri de denilmekte olup genellikle rüzgar hızına uyması için yüksek boyutlu lineer olmayan denklemler oluştururlar (Liu ve ark., 2014). İstatistiksel yöntemler yaygın olarak otoregressive (AR), otoregressive hareketli ortalama (ARMA), kuantil regresyon modelini (QR) ve Kalman-filtre modellerini içerir. Bu modeller, hem basit hem de hızlı olduklarından doğrusal, durağan zaman serileri için çok uygundur (Wang ve ark., 2015).

Bir AR modelinde, bağımlı değişken geçmişteki değerinin bir fonksiyonudur. Birçok zaman serisi verisi de bu süreci içermektedir. Bu durum aşağıdaki gibi bir denklemlerle ifade edilebilir (Şenkal, 2014).

$$x^t = a + a^2x^{(t-1)} + a^2x^{(t-2)} + a^2x^{(t-3)} + \dots + \varepsilon \quad (4.20)$$

Burada, a, sabit terimi temsil ederken  $a^1$  gibi katsayılarında gecikmeli değerlerin şimdiki değerle olan ilişkisini temsil eder. Ayrıca  $\varepsilon$  hata terimi olarak tanımlanmaktadır. Genel bir şekilde AR(p) şeklinde ifade edilir. Eğer serinin gecikmeli hata terimi, şimdiki hata terimini etkiliyorsa hareketli ortalama süreci tanımlanır. Bir hareketli ortalama sürecinde değişkenin tahmin değeri hata terimlerinin tahmin değeri ile ilgilidir. Bir hareketli ortalama süreci,

$$x_t = e_t - (a_1e_{(t-1)}) - \dots, t = 1, 2, \dots, n \quad (4.21)$$

şeklinde ifade edilebilir. Genel olarak hareketli ortalama, MA(q) şeklinde ifade edilir. Hareketli ortalama sürecinde, her bir gecikmeli hata terimi onun şimdiki değerini etkilemektedir. Otoregresif Hareketli Ortalama (ARMA) modelleri, rüzgar hızı veya gücünün gelecek değerlerinin tahmininde, zaman serilerine dayalı yaklaşımlardaki en popüler modellerdir. Otoregresif Entegre Hareketli Ortalama (ARIMA), mevsimsel-ARIMA (seasonal-ARIMA) ve parçalı-ARIMA (fractional-ARIMA), sistem dışı değişken girişli ARMA (ARMAX veya ARX) bu modelin varyasyonlarıdır. Gri tahminleyiciler, doğrusal tahminleyiciler, üstel düzeltme vb. zaman serilerine dayalı modeller de mevcuttur (Şenkal, 2014).

#### 4.1.6 Hibrit modeller

Hibrit modeller, birden fazla yöntemin en iyi yanlarını kullanarak tahminler için birleştirme esasını üzerine kurulmaktadır. Yaygın olarak rüzgar enerjisi tahminlerinde kullanılan hibrit modeller; fiziksel ve istatistiksel yaklaşımların birleşimi, kısa süreli ve orta süreli tahmin modellerinin birleşimi ve alternatif istatistiksel modellerin birleşimiyle oluşturulmaktadır (Wu ve Hong, 2007). İstatistiksel ve fiziksel kuramların birleşimiyle

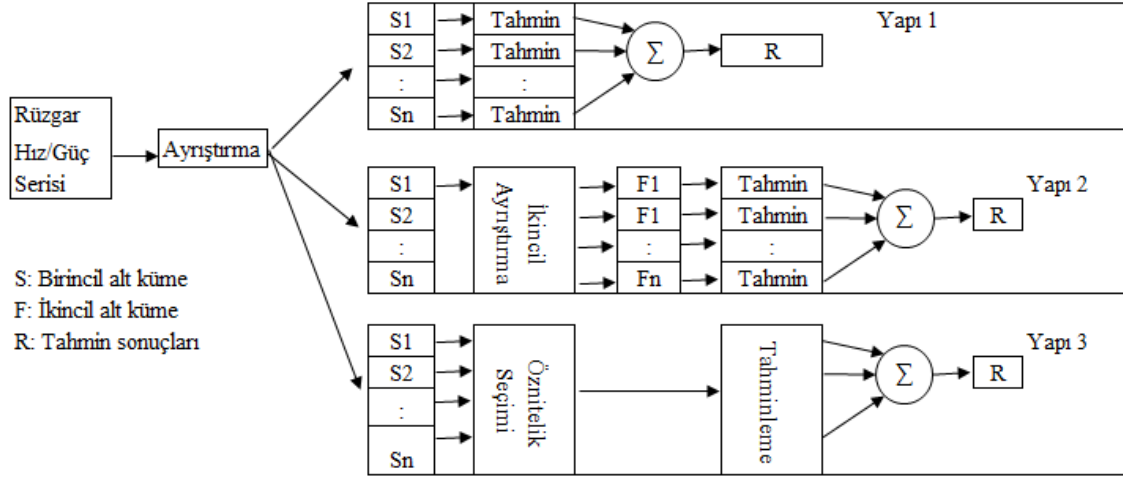
oluşturulan modellerde; zaman serisi modellerinin kısa süreli tahminlerdeki başarısı ve fiziksel yöntemlerin uzun süreli tahminlerdeki başarısı model için avantaj sağlamaktadır (Cantürk, 2018).

Rüzgar hızının son derece dengesiz bir karakteristiğe sahip olması tekli yapay zeka modellerinin tahmin doğruluğunda istenilen performansı yakalamasını zorlaştırmaktadır. Bundan dolayı günümüzde rüzgar hızı tahmininde popüler hale gelen hibrit modeller geliştirilmiştir. Bu durum tez çalışmasında hibrit modele yönelmede ışık olmuştur. Hibrit modellerin oluşturulmasında iki temel yaklaşım kullanılmaktadır. Bunlardan ilki sezgisel optimizasyon algoritmalarıdır. Crisscross optimization algoritması (COA), yerçekimi arama algoritması (GSA), parçacık sürüsü optimizasyonu (PSO), genetik algoritma (GA) vb. gibi sezgisel optimizasyon algoritmaları kullanılmaktadır. İkinci yaklaşım ise orijinal zaman serisine çeşitli ayrıştırma teknikleri uygulamaktır. Günümüzde, sıklıkla kullanılan tek ayrıştırma yaklaşımlarına ek olarak, ikincil ayrıştırma yöntemleri de araştırılmış ve genellikle tek ayrıştırma yöntemlerinden daha iyi performans sergilediği belirlenmiştir. Tekli zaman serisi ayrıştırma tekniklerinin çoğunda tahminleme yapılmadan önce eğitim veri seti (bilinen bilgi) ve test veri seti (bilinmeyen bilgi) dahil olmak üzere tüm ham seri, sadece bir kez ayrıştırılmıştır. Ayrıştırma neticesinde elde edilen birinci içsel mod fonksiyonu (IMF), anti-kalıcı özelliği ile ana veriye olan benzerliği, çalışmalarda ikincil ayrıştırmayı birinci IMF üzerinden yapılması yönünde olmuştur. Birinci ve ikinci ayrıştırma sonucu elde edilen alt fonksiyonlar, ana verinin özelliklerini yansıtmakla beraber daha durağan bir fonksiyon olarak tahminleme performansı üzerinde etkilidirler.

## 4.2 Ayrıştırma Teknikleri

Genel olarak, Şekil 4.2'de gösterildiği gibi, literatürde üç ayrıştırma bazlı modelin yapısı bildirilmiştir. Ayrıştırma bazlı hibrit modellerin temeli, rüzgar hız/güç zaman serisini nispeten durağan özelliklere sahip birkaç alt kümeye ayrıştırmaktır. Birinci yapı farklı modelleri kullanarak her alt kümeyi analiz ve tahmin eder. İkinci yapıda, ayrıştırılmış alt kümeler ikincil ayrıştırma yöntemi kullanılarak bir dizi daha sabit alt kümeye ayrıştırılır, daha sonra her alt küme, birinci yapıdaki gibi aynı şekilde tahmin edilir (Hui-Liu ve ark., 2015; Liu ve ark., 2010). Nihai sonuçlar, birinci ve ikinci yapı için her bir alt kümeden

yapılan tahminlerin birleştirilmesiyle elde edilir. Her bir alt kümeyi öngörmekten farklı olarak, girdilerin ayrıştırılmış alt kümelerden seçilen tek bir tahmin modeli üçüncü yapıda oluşturmuştur (Ramesh ve Arulmozhivarman, 2013; Wei ve ark., 2016).



Şekil 4.2. Ayrıştırma Tabanlı Model Yapısı (Qian ve ark., 2019)


Qian ve ark. (2019) yaptıkları çalışmada, literatürde bildirilen 101 tane rüzgar tahmin ile ilgili yayın araştırmışlar ve bunların ayrıştırma tabanlı hibrit yöntemlerle ilgili olduğunu tespit etmişlerdir. 88 yayınlı en popüler yöntemin birinci yapıya ait olmasına rağmen diğer yapıların da önemli olduğunu bildirmişlerdir. Ayrıca bazı makalelerde bu yapıların karşılaştırıldığını da belirtmişlerdir. Hui-Liu ve ark. (2015), birinci ve ikinci yapı için birçok karşılaştırmalı vaka çalışması yapmışlardır. Vaka sonuçlarında, hem birinci yapının hem de ikinci yapının, çok aşamalı rüzgar hızı tahmininde tekli modelden daha iyi performans gösterdiğini göstermişlerdir. Yani ikinci yapı, birinci yapıdan çok daha iyi tahmin sonuçları sunmaktadır. Bununla birlikte, ikincil ayrıştırma prosedürü ile ikinci yapının, birinci yapıdan çok daha fazla hesaplama kaynağı gerektirdiğini de vurgulamışlardır.

Ren ve ark. (2014, 2015), Singapur'daki bir sahadan 10 dakikalık adımlı rüzgar hızı verilerine dayanarak birinci ve üçüncü yapının stratejilerini karşılaştırmışlardır. EMD-SVR ve EMD-KNN modellerini hem birinci yapı hem de üçüncü yapı için değerlendirmişler ve sonuçlara göre her iki ayrıştırma temelli yapının, tekli tahmin modellerinden daha iyi performans gösterdiği ortaya koymuşlardır. Ancak üçüncü yapı



kısa öngörme döngüsünde birinci yapıdan biraz daha iyi olduğunu göstermişlerdir. Uzun döngüde ise birinci yapının kullanılmasının zorunlu olmadığını bununla birlikte üçüncü yapının yalnızca bir tahmin modeli oluşturduğu için birinci yapıdan çok daha az hesaplama kaynağı kullandığı belirtmişlerdir.

Ayrıştırma bazlı hibrit modeller, ayrıştırma algoritmaları ve tahmin algoritmaları açısından sınıflandırılabilir. Dalgacık ve Ampirik Mod Ayrıştırma tabanlı yöntemler, en yaygın kullanılan ayrıştırma yöntemlerinden ikisidir. Bunların yanı sıra, Mevsimsel Ayarlama Yöntemi (SAM) (Gou ve ark., 2011; Zhang ve ark., 2013), Değişken Mod Ayrıştırma (VMD) (Abdoos, 2016; Peng ve ark., 2017) ve İçsel Zaman Ölçeği Ayrıştırması (ITD) gibi literatüründe birçok ayrıştırma yaklaşımları da bildirilmiştir (Zhang ve ark., 2016). Ayrıştırılmış her alt küme için tahmin yöntemleri genellikle ARMA, YSA ve SVM gibi farklı konfigürasyonlarla aynı modeldir. Bununla birlikte, bazı durumlarda, her alt grubun özelliklerine bağlı olarak farklı modeller kullanılır (Tasçıkaraoğlu ve Uzunoğlu, 2014). Şekil 4.3, ayrıştırma bazlı hibrit rüzgar tahmin modellerinin sınıflandırılmasını göstermektedir. Dalgacık tabanlı modellerin ve ampirik mod bazlı modellerin hemen hemen aynı oranı paylaştığı görülürken, YSA modelleri ve SVM modellerinin hem dalgacık tabanlı modeller hem de ampirik mod tabanlı modeller için en geniş kapsamlı olarak çalışıldıkları görülmektedir.



Şekil 4.3. Ayrıştırma Tabanlı Hibrit Sistemlerin Sınıflandırılması (Qian ve ark., 2019)

#### 4.2.1 Ampirik dalgacık dönüşümü (EWT, Empirical Wavelet Transform)

EWT, Jerome Gilles tarafından önerilen yeni bir sinyal işleme tekniğidir (Huang ve ark., 1998). EWT, analiz edilen sinyalin spektrum bilgisine bağlı olan bir grup geçiş filtresi oluşturur. EWT şu şekilde gerçekleştirilebilir: Analiz edilen sinyalin Fourier desteği  $[0, \pi]$  N bitişik segmente ayrılır. Her bir segment  $\Lambda_n = [\omega_{n-1}, \omega_n]$  olarak ifade edilir.  $\omega$  açılmal hızı göstermektedir. Ampirik ölçekleme fonksiyonu ve ampirik dalgacıklar sırasıyla Denklem 4.22 ve 4.23 kullanılarak hesaplanır.

$$\widehat{\phi}_n(\omega) = \begin{cases} 1 & \text{if } |\omega| \leq (1 - \gamma)\omega_n \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\gamma\omega_n} (|\omega| - (1 - \gamma)\omega_n) \right) \right] & \text{if } (1 - \gamma)\omega_n \leq |\omega| \leq (1 + \gamma)\omega_n \\ 0 & \text{Aksi durumda} \end{cases} \quad (4.22)$$

$$\widehat{\psi}_n(\omega) = \begin{cases} 1 & \text{if } (1 + \gamma)\omega_n \leq |\omega| \leq (1 - \gamma)\omega_{n+1} \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\gamma\omega_{n+1}} (|\omega| - (1 + \gamma)\omega_n) \right) \right] & \text{if } (1 + \gamma)\omega_n \leq |\omega| \leq (1 + \gamma)\omega_{n+1} - \gamma\omega_{n+1} \\ \sin \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\gamma\omega_n} (|\omega| - (1 - \gamma)\omega_n) \right) \right] & \text{if } (1 - \gamma)\omega_n \leq |\omega| \leq (1 + \gamma)\omega_n - \gamma\omega_n \\ 0 & \text{Aksi durumda} \end{cases} \quad (4.23)$$

$$w_f^\varepsilon(0, t) = \langle f, \phi_1 \rangle = \int f(\tau) \overline{\phi_1(\tau - t)} d\tau = (\hat{f}(\omega) \overline{\widehat{\phi}_1(\omega)})^\vee \quad (4.24)$$

$$w_f^\varepsilon(n, t) = \langle f, \psi_n \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau = (\hat{f}(\omega) \overline{\widehat{\psi}_n(\omega)})^\vee \quad (4.25)$$

Bununla birlikte sunulan algoritmanın geçerliliğinin korunması için bazı kısıtlamalar vardır. Örneğin, 4.22 ve 4.23 no'lu denklemde yer alan  $\gamma$  oranı ampirik ölçekleme fonksiyonunu ve ampirik dalgacıkları  $L^2(R)$  'nin dar bir ölçeği olarak  $\gamma < \min_n \frac{(\omega_{n+1} - \omega_n)}{(\omega_{n+1} + \omega_n)}$  gibi küçük bir değerle sınırlandırılır.  $\beta(x)$  genellikle  $\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3)$  ile tanımlanır. Orijinal sinyal, aşağıdaki gibi tanımlanan çeşitli ampirik modlara ayrıştırılabilir:

$$f_0(t) = w_f^\varepsilon(0, t) * \phi_1 \quad (4.26)$$

$$f_k(t) = w_f^\varepsilon(k, t) * \psi_k \quad (4.27)$$

Ve ters ampirik dalgacık dönüşümü aşağıdaki denklemle gerçekleştirilebilir:

$$\begin{aligned} f(t) &= w_f^\varepsilon(0, t) * \phi_1(t) + \sum_{n=1}^N w_f^\varepsilon(n, t) * \psi_n(t) \\ &= \left( (\widehat{w}_f^\varepsilon(0, \omega) * \widehat{\phi}_1(\omega)) + \sum_{n=1}^N \widehat{w}_f^\varepsilon(n, \omega) * \widehat{\psi}_n(\omega) \right)^\vee \end{aligned} \quad (4.28)$$

Çalışmalarda, ters ampirik dalgacık dönüşümü, tahmin serisinin aykırı değerlerini düzeltmek için kullanılmaktadır. Bunu gerçekleştirmek için eğitim serisinin spektrum segmentleri, eğitim ve tahmin serilerinin birleştirildiği kombine serilerin tahminlemesi olarak kullanılır (Gilles, 2013).

#### 4.2.2 Ampirik mod ayrıştırma (EMD, Empirical Mode Decomposition)

Ampirik mod ayrıştırması (EMD), Huang ve arkadaşları tarafından geliştirilen Hilbert-Huang dönüşümüne dayanarak formüle edildi. EMD, farklı içsel zaman skalasına bağlı olarak ortaya çıkan enerjinin doğrudan ayrıştırılmasına dayanmakta ve zaman serisini İçsel Salınım Fonksiyonlarına (IMF, Intrinsic Mode Function) ayrıştırmaktadır. IMF, yerellik ve uyarlanabilirlik özellikleri göstermektedir. Yerellik ve uyarlanabilirlik doğrusal olmayan ve/veya durağan olmayan zaman serilerinin analizi için gerekli ön koşullardır (Huang ve ark., 1998). IMF, özetle iki ön koşulu sağlayan fonksiyon olarak tanımlanabilir. Bu koşullar:

1) Tüm veri seti içerisinde, tepe ve sıfır geçiş noktalarının sayısı eşit veya aralarındaki fark en çok bir olmalıdır. Bu sebeple fonksiyonun dar bant genişliğine sahip olma koşulu sağlanmış olmaktadır.

2) Verinin rastgele bir noktasında, yerel maksimum ve yerel minimum noktalarının her ikisinde ayrı ayrı kullanılarak oluşturulan zarf fonksiyonlarının ortalaması sıfır olmalıdır.

Böylece, genel koşul yerine yerel bir koşul uygulanmakta ve ideal olarak, söz konusu koşul; verinin yerel ortalamasının sıfır olmasını ifade eder; ancak durağan olmayan

verilerde yerel ortalama hesaplanabilmesi için yerel zaman skalasının kesin belirlenmesi gereklidir ki bu imkansızdır. Bu sebeple, yerel ortalama yerine yerel maksimum ve minimum noktalarından geçen zarf fonksiyon değerlerinin ortalaması kullanılmaktadır (Huang ve ark., 1998). Zaman skalasının rastgele bir noktasında veri seti, birden çok salınım içerebilir. Veri setinin barındırdığı salınımlar ayrıştırılarak IMF fonksiyonları elde edilmelidir. EMD, doğrusal olmayan ya da durağan olmayan veri setlerini IMF'lere ayırmak için geliştirilen bir yöntemdir. Birçok veri analiz yöntemlerinin yerine, EMD veri setinin içindeki salınımları direkt ayırtmaya yönelik uyarlanabilir, önsel ve veri odaklı bir yöntemdir. EMD yöntemi üç temel varsayıma dayanmaktadır:

- 1) Veri seti veya sinyal en azından iki adet tepe nokta -bir minimum ve bir maksimum olacak şekilde- içermektedir.
- 2) Verideki salınımın özellikleri, tepe noktalar arasındaki zaman aralığı ile yani karakteristik zaman skalası ile belirlenmektedir.
- 3) Eğer veri seti tepe nokta olmamasına karşın bükülme noktalarına sahipse, veri seti bir ya da daha fazla ayrıştırma işlemine tabi tutularak tepe noktalar ortaya çıkarılabilir.

Yöntemin temelini içsel salınımların karakteristik zaman skalaları yardımıyla ampirik olarak tespit edilerek veri setinin IMF bileşenlerine ayrıştırılmasını oluşturur (Huang ve ark., 1998). Her IMF, orijinal sinyalin dinamik özelliklerini yansıtan gizli bir salınım modu olarak tanımlanabilir. IMF aşağıdaki iki koşulda sınırlıdır:

- (1) Bütün bir veri setinde, ekstrem sayısı (maksimum sayısı ve minimum sayısı) ve sıfır geçiş sayısı eşit olmalı veya en fazla bir farklılık göstermelidir.
- (2) Herhangi bir noktada, yerel maksimum tarafından tanımlanan zarfın ve yerel minimum tarafından tanımlanan zarfın ortalama değeri sıfırdır.

IMF aşağıdaki adımlar yoluyla elde edilebilir:

Adım 1: Rüzgar hızı sinyali  $x(t)$  için,  $x(t)$  'nin tüm yerel uçlarını tanımlanır.

Adım 2: Üst makbuzu  $x_1(t)$  üretmek için kübik bir şerit kullanarak tüm maximumları bağlanır. Aynı şekilde, tüm zarfları bağlayarak alt zarfı  $x_2(t)$  üretilir.

Adım 3: Üst ve alt zarfların ortalama değerini  $m$  hesaplanır ve  $x(t)$  ve  $m$  arasındaki farkı  $h$  olarak tanımlanır.

$$h = x(t) - m \quad (4.29)$$

$$m = \frac{x_1(t) + x_2(t)}{2} \quad (4.30)$$

Adım 4:  $h$ , bir IMF olana kadar Adım 3'ü tekrarlanır. IMF kriteri aşağıdaki denklem ile ifade edilir:

$$\sum_{t=1}^N \left( \frac{(m_{t-1} - m_t)^2}{(m_{t-1})^2} \right) \leq \partial \quad (i = 1, 2, \dots; t = 1, 2, \dots, N) \quad (4.31)$$

$N$ , sinyalin uzunluğu olduğunda, yinelemeli hesaplamaların sayısını ve  $\partial$  önceden belirlenmiş bir değerdir (Cantürk, 2018). Karakteristik zaman skalaları önceden belirlenmiş fonksiyonlar yerine, serinin kendi doğasına uygun olarak -yerel uç noktalar kullanılarak belirlendiği için IMF fonksiyonları serinin fiziksel dinamiklerini yansıtmaktadır (Torun, 2012).

Bununla birlikte, EMD uygulaması sırasında hala bazı sınırlamalar vardır. En büyük sınırlamalardan biri mod karıştırma problemidir. Mod karıştırma, bir IMF'de farklı ölçeklerin bir sinyalinin olduğu veya benzer bir ölçek sinyalinin farklı IMF'lerde bulunduğu anlamına gelir. EEMD (Wu ve ark., 2011), CEEMD (Yeh ve ark., 2011) ve CEEMDAN (Torres, 2011) gibi mod karıştırma problemlerini çözmek için çeşitli geliştirilmiş EMD yöntemleri önerilmiştir. EMD ve EMD'nin geliştirilmiş versiyonları Çizelge 4.2'de gösterilmektedir. Son yıllarda, EMD ve iyileştirilmiş versiyonları rüzgar tahminlerinin uygulanmasında bildirilmiştir. Genellikle rüzgar hızı/güç zaman serilerini düz ve sabit bir IMF bileşenleri ve bir artık bileşen topluluğuna ekleyerek rüzgar tahmin performansını artırmak için uyarlanırlar, ardından her bileşen tahmin modeli kullanılarak ayrı ayrı tahmin edilir. (Ren ve ark., 2015).

Çizelge 4.2. EMD ve geliştirilmiş versiyonlarının karşılaştırılması (Ren ve ark., 2015)

<b>METOT</b>	<b>AVANTAJLARI</b>	<b>DEZAVANTAJLARI</b>
EMD	Uyarlanabilir	Mod karıştırma
EEMD	Uyarlanabilir, Mod karıştırma problemini çözme yeteneği, Yeniden yapılandırılmış sinyalde fazladan gürültü yok	Yeniden yapılanmış sinyalde ekstra gürültü var, Çok fazla hesaplama kaynağına ihtiyacımız var.
CEEMD	Uyarlanabilir, Mod karıştırma problemini çözme yeteneği, Yeniden yapılandırılmış sinyalde fazladan gürültü yok	Çok fazla hesaplama kaynağına ihtiyacımız var.
CEEMDAN	Uyarlanabilir, Mod karıştırma problemini çözme yeteneği, Yeniden yapılandırılmış sinyalde fazladan gürültü yok	Sıralı prosedür, paralel hesaplama ile gerçekleştirilemez.

#### 4.2.3 Topluluk ampirik mod ayrıştırma (EEMD, Ensemble Empirical Mode Decomposition Method)

Topluluk Ampirik Mod Ayrıştırma (EEMD) yöntemi EMD yönteminin mirasçısıdır ve mod karıştırma problemini ortadan kaldırmak için Wu ve Huang (2009) tarafından önerilmiştir. Mod karıştırma, farklı IMF bileşenlerinde ortaya çıkan dramatik olarak çaresiz ölçeklerin salınımlarına sahip bir sinyalin görünümüdür. EEMD yönteminde, gerçek IMF sinyalleri, yeni seslerin bir araya gelmesiyle bir denemeler topluluğunun teması olarak tanımlanır. EEMD yönteminin sürecinde, her deneme, sonlu beyaz bir gürültü ilavesiyle, derli toplu sinyallerden oluşur. Genişlik ve beyaz sesler alandayken kendinden uyarlamalı bir filtre olarak çalışır (Flandrin ve ark., 2004). EEMD yönteminde,

beyaz gürültü orijinal rüzgar verilerine eklenir. Ardından, zaman serileri EMD yönteminde olduğu gibi aynı prosedürle sınırsız sayıda IMF'ye ayrıştırılır. Spesifik genlik aralıklarının farklı beyaz sesleri ile bu iki adım tekrarlanır ve karşılık gelen IMF bileşenleri türetilir. Prosedürün tekrarı birkaç sınırlı sayıda yapılır. Bu sayılar, topluluk sayıları olarak bilinir. Tüm IMF'lerin ortalaması ve her bir tekrarın kalıntısı, nihai IMF'ler ve EEMD yöntemiyle türetilen kalıntı olarak kabul edilir. Bununla birlikte, bu IMF'lerin ve tortunun kombinasyonu, orijinal zaman serileri ile aynı olmayacaktır. Pek çok makale (Hu ve ark., 2013; Yu ve ark., 2017; Wang ve ark., 2016), sorunsuz IMF'leri nedeniyle EEMD yönteminin daha iyi tahmin performansı için kullanılmasını desteklemiştir. EEMD yönteminin her IMF'sinde, aynı ölçeklendirilmiş frekanslar elde edilir (Bokde ve ark., 2018).


Bununla birlikte, EMD'nin mod karıştırmasının birincil dezavantajı nedeniyle, EEMD olarak bilinen yeni bir gürültü destekli sinyal analiz tekniği önerilmektedir. Genel olarak, EEMD beyaz gürültüden yararlanır ve etkili bir kendinden uyarlamalı dinamik filtre bankası oluşturur (Li ve Shi, 2012; Liu ve ark., 2015). IMF bileşenleri bir iz grubunun ortalaması olarak tanımlanır ve sonlu genlikteki beyaz gürültü artı sinyalin ayrışma sonuçlarından oluşur (Wu ve Huang, 2009).

#### **4.2.4 Varyasyonel mod ayrıştırma (VMD, Validation mode decomposition)**

Varyasyonel Mod Ayrıştırma (VMD), orijinal zaman serisini üretirken belirli seyreklik özelliklerine sahip birkaç mod da parçalayan nispeten yeni bir ayrışma algoritmasıdır. VMD algoritmasını rüzgar hızı/güç tahminine dahil etmeye yönelik birkaç yayın üzerinde durulmuş ve buna karşılık gelen sonuçlar, tahmin modellerinin WD ve EMD yöntemleriyle karşılaştırıldığında VMD ile birleştirilirken daha iyi performans göstereceğini göstermiştir (Abdoos, 2016, Naik ve ark., 2017). VMD, sırasıyla Liu ve ark. (2018), WD ve CEEMDAN tarafından elde edilen alt kümeleri ayırmak için ikincil ayrıştırma yöntemi olarak benimsenmiştir. Sonuçlar, rüzgar hızı tahmin performansını arttırmada iki aşamalı ayrıştırma stratejisini kullanmanın etkinliğini doğrular.

## 5. MATERYAL ve YÖNTEM


Bu tez çalışmasında kullanılan rüzgar hızı verileri Tokat Gaziosmanpaşa Üniversitesi kampüsü içerisine kurulan ölçüm istasyonundan toplandı. (N 40°19'58.73") enlemi ve (E 36°29'0.28") boylamına yerleştirilen ölçüm istasyonunda yer alan ölçüm direği Şekil 5.1'de gösterilmektedir.



Şekil 5.1. Ölçüm Direği

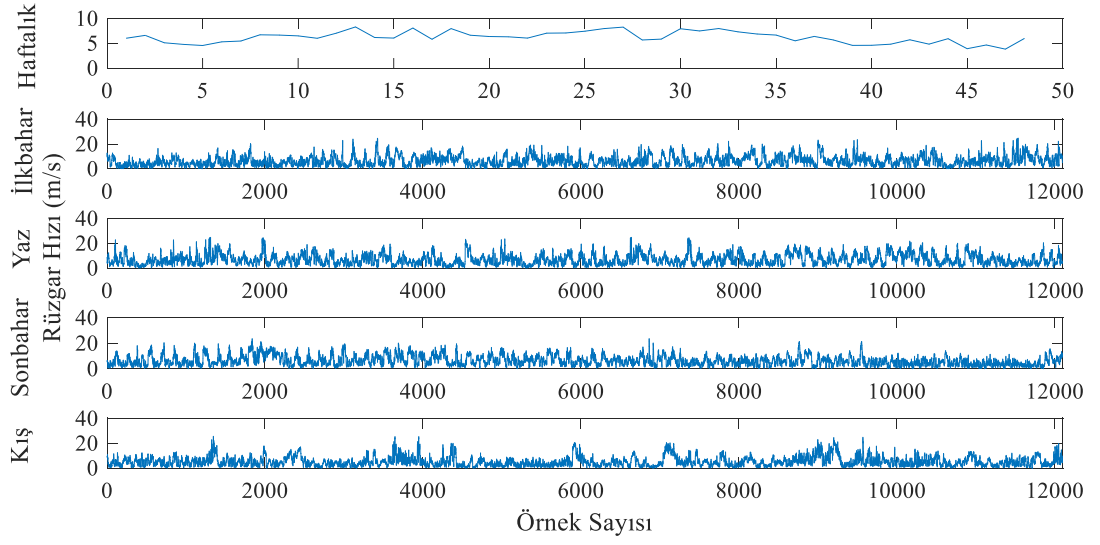
Ölçüm direği 12 m yüksekliğinde olup üzerinde 2 adet rüzgar hızı ölçüm sensörü ve 1 adet rüzgar yönü ölçüm sensörü bulunmaktadır. Basınç, sıcaklık ve nem sensörleri direğin alt kısmına montaj edilen güç kutusuna yerleştirilmiştir (Şekil 5.2). Sensörlerin ihtiyaç duyduğu enerji 10 W'lık solar panel ile sağlanmaktadır. Ayrıca başka çalışmalarda da kullanılmak üzere ölçüm direğinin üzerine AIR-X 400W rüzgar türbini yerleştirilmiştir.





Şekil 5.2. Güç Kutusu

Rüzgar hızı verileri 2017 – 2019 yılı boyunca 10’ar dakika aralıklar ile kaydedildi. Haftalık ve mevsimsel tahminlemelerde kullanılmak üzere veriler kendi içerisinde gruplandırıldı. Haftalık tahminlemelerde her ayın haftalarına karşılık gelen verilerin ortalaması alındı ve bir yıl için 48 adet veriye sahip bir çalışma seti oluşturuldu. Mevsimsel analizlerde ise ilkbahar (Şubat, Mart, Nisan), yaz (Mayıs, Haziran, Temmuz), sonbahar (Ağustos, Eylül, Ekim) ve kış (Kasım, Aralık, Ocak) mevsimleri için veriler düzenlenerek her bir mevsim için 12.096 adet verinin bulunduğu çalışma seti düzenlendi. Verilerin değişimleri Şekil 5.3’de gösterilmektedir.



Şekil 5.3. Haftalık ve Mevsimsel Veri Setleri

Her bir veri setindeki verilere ait ortalama değer, maksimum değer, minimum değer ve standart sapmayı içeren istatistiksel bilgiler Çizelge 5.1’de listelenmektedir.

Çizelge 5.1. Haftalık ve Mevsimsel veri setine ait istatistiksel bilgiler

Özellikler	Ortalama Değer	Maksimum Değer	Minimum Değer	Standart Sapma	
Haftalık	6,2141	8,2967	3,8203	1,1682	
Mevsimler	İlkbahar	6,4364	24,7260	0,0180	3,9936
	Yaz	6,9202	24,1260	0,1200	4,2879
	Sonbahar	6,4382	23,5620	0,0350	3,8840
	Kış	5,2095	25,5400	0,0194	3,9077

Rüzgar hızı tahminlemede önerilen hibrit model her bir veri seti için uygulanmıştır. Hibrit model veri ön işleme, kümeleme, tahmin ve değerlendirme olmak üzere dört modülden oluşmaktadır. Bu bölümler ham veri serisi içindeki gürültünün etkisini azaltmak ve özellikleri çıkarmada elverişli bir seri elde etmek için yüksek frekanslı sinyallerin kaldırılması işlemlerini, rüzgar hızı verileri içindeki benzerlik özelliğini

çıkarmak için hurst analizini, geri yayımlı yapay sinir ağlarını içeren tahmin modelini ve tahmin performansının genel tahmin doğruluğu yaygın olarak kullanılan üç genel hata değerlendirme endekslerini içermektedir.

### 5.1 Uyarlanabilir Gürültüyle Tamamlanan Topluluk Ampirik Mod Ayrıştırma (CEEMDAN, Complete Ensemble Empirical Mode Decomposition Adaptive Noise)

Zaman serisi Ampirik mod ayrıştırma (EMD) tekniğini kullanarak bir dizi içsel mod fonksiyona (IMF) ayrıştırılabilir. Her IMF'de sadece bir salınım modu vardır ve bu iki temel prensibi karşılar (Bajaj ve Pachori, 2012; Hassan ve Bhuiyan, 2016). İlk prensip toplam veri setinde, sıfır geçiş sayısının ve uç nokta sayısının eşit ya da farklı olması gerektiğini belirtir. İkincisi ise, IMF'nin herhangi bir noktasında, yerel minimum ve yerel maksimum tarafından tanımlanan zarfların ortalama değeri sıfırdır. EMD'ye kıyasla sahip olduğu avantajlar sayesinde CEEMDAN işaret işleme teknikleri arasında yaygın olarak tercih edilmekte ve kullanılmaktadır. EMD, aynı ve farklı mod da bulunabilen çeşitli salınım türleri gibi karışık mod özelliği sergiler. Diğer yandan CEEMDAN, tüm IMF'ler ve terminal kalıntısı eklenerek tam olarak yeniden yapılandırılabilir ve modlara daha iyi bir spektral ayrışma sağlar (Torres ve ark., 2011). CEEMDAN, temel bir fonksiyona ihtiyaç duymaması, düşük hesaplama maliyeti ve veri odaklı yapısı nedeniyle yüksek derecede durağan ve doğrusal olmayan sinyalleri işlemek için güçlü bir araçtır (Hassan ve Haque, 2015).  $w^i$   $i = 1, 2, \dots, I$  sıfır ortalama ve birim varyanslı Beyaz Gauss gürültüsünün farklı gerçekleştirilmesini temsil etsin. Beyaz Gauss gürültüsünün standart sapması  $\varepsilon_0$  ile ifade edilir. Operatör  $E_j(\cdot)$ , EMD'nin  $j$ -th modunu üreten olarak tanımlanır. Bu tanımlamalardan sonra CEEMDAN aşağıdaki adımları içermektedir (Smith, 2005):

1. adım:  $x(n) - \varepsilon_0 w^i(n)$  hesaplanır.
2. adım: Bahsedilen  $I$  sinyallerini ayırmak ve ilk modlarını elde etmek için EMD yöntemini kullanılır.
3. adım: Birinci mod hesaplanır

$$IMF_1(n) = \frac{1}{I} \sum_{i=1}^I imf_1^i(n) \quad (5.1)$$

4. adım: İlk kalıntı bulunur

$$r_1(n) = x(n) - IMF_1(n) \quad (5.2)$$

5. adım: Ayrıştırmayı  $r_1(n) + \varepsilon_1 E_1(w^i(n))$   $i = 1, 2, \dots, I$  ile ilk EMD moduna kadar gerçekleştirilir.  $\varepsilon_k$   $k$ . aşamadaki beyaz Gauss gürültüsünün standart sapmasıdır.  $IMF_2(n)$  aşağıdaki ifade ile hesaplanır:

$$IMF_2(n) = \frac{1}{I} \sum_{i=1}^I E_1(r_1(n) + \varepsilon_1 E_1(w^i(n))) \quad (5.3)$$

6. adım:  $k = 2, 3, \dots, K$  için  $k$ . kalıntı hesaplanır

$$r_k(n) = r_{k-1} - IMF_k(n) \quad (5.4)$$

7. adım: Ayrıştırma  $r_1(n) + \varepsilon_1 E_1(w^i(n))$   $i = 1, 2, \dots, I$  ile ilk EMD moduna kadar gerçekleştirilir ve  $(k+1)$ . modu aşağıdaki eşitlik ile tanımlanır:

$$IMF_{k+1}(n) = \frac{1}{I} \sum_{i=1}^I E_1(r_k(n) + \varepsilon_k E_k(w^i(n))) \quad (5.5)$$

8. adım: Sonraki  $k$  için 6. adıma gidilir

Kalıntı monotonik bir fonksiyon haline gelinceye kadar her IMF'yi çıkarmak için 6 ile 8 arasındaki adımlar uygulanır. Son olarak orijinal  $x(n)$  eşitlik 13'deki gibi yazılır.

$$x(n) = \sum_{k=1}^K IMF_k(n) + r_k(n) \quad (5.6)$$

$K$  toplam mod sayısıdır ve  $r_k(n)$  son kalıntıdır.

## 5.2 Lokal Ortalama Ayırıştırması (LMD, Local Mean Decompositon)

Mekanik sinyaller, içerisinde karmaşık Fourier spektrumuna sahip çok sayıda bileşen içerir. LMD, çok bileşenli bir sinyali, üretim fonksiyonu (PF, Production function) olarak adlandırılan mono bileşenlerin bir dizisine parçalayabilir. Her product fonksiyonu (PF), bir genlik zarf sinyalinin ve saf frekans modülasyonlu bir sinyalin ürünüdür. Bu durum doğrudan Hilbert transform (HT) olmadan anlık genlik (IA) ve anlık frekans (IF)'ı türetebileceği anlamına gelir. EMD ile karşılaştırıldığında Hilbert dönüşümünden kaçınmak bu yöntemin en belirgin avantajıdır. Bu çalışmada ikinci ayırıştırma tekniği olarak LMD yöntemin seçilmesindeki diğer şunlardır: LMD yineleme işlemi düzleştirilmiş yerel araçlar ve yerel büyüklükler kullanır. Böylece EMD'de kullanılan kübik spline yaklaşımını önler. Çünkü bu yaklaşım zarf hatalarının oluşmasına neden olur ve anlık frekans ile genliğin doğruluğunu etkileyebilir. Bununla birlikte daha hızlı bir algoritma hızına sahiptir. Ek olarak ani frekansın açık olmayan uç etkisi ve daha az gürültülü bileşenleri ve daha az tekrarlamalı süreler LMD'nin pratikte daha fazla uygulama için kullanılmasını mümkün kılar (Cheng ve ark., 2012). LMD'nin temel fikri, bir frekans modülasyonu (FM) sinyalini kademeli olarak bir genlik modülasyonu (AM) zarf sinyalinden ayırmaktır. Bu işlem aşağıdaki gibi tanımlanabilir (Smith, 2005).

1. adım: Verilen sinyalin  $x(t)$  tüm yerel uç noktaları tanımlanır. Extrem  $n_{ij}(t_k)$  indeks  $t_k$  tarafından ayrılır ve ifadede yer alan  $i = 1, 2, \dots, m$ ;  $j = 1, 2, \dots, n$  ve  $k = 1, 2, \dots, K$ ; sırasıyla PF, yineleme ve extrem sayısını ifade eder.

$$m_{ij}(k) = \frac{n_{ij}(t_k) + n_{ij}(t_{k+1})}{2} \quad (5.7)$$

$$a_{ij}(k) = \frac{|n_{ij}(t_{k+1}) - n_{ij}(t_k)|}{2} \quad (5.8)$$

2. adım: Lokal ortalamalar ve lokal genlikler sırasıyla lokal ortalama fonksiyonu  $m_{ij}(t)$  ve zarf fonksiyonu  $a_{ij}(t)$  'nun hareketli ortalama formunu kullanarak yumuşatılır.

3. adım: Lokal ortalama fonksiyonu  $m_{11}(t)$ 'yi  $X(t)$ 'den aşağıdaki gibi çıkartılır:

$$h_{11} = X(t) - m_{11}(t) \quad (5.9)$$

Sonra  $h_{11}(t)$  zarf fonksiyonu  $a_{11}(t)$  tarafından bölünür ve şu şekilde hesaplanır:

$$s_{11} = h_{11}(t) / a_{11}(t) \quad (5.10)$$

Bu prosedür, tamamen frekans modülasyonlu bir sinyal  $s_{1n}$  elde edilinceye kadar tekrar etmelidir. Bu şöyle ifade edilir:

$$\begin{cases} h_{11} = X(t) - m_{11}(t) \\ h_{12} = s_{11}(t) - m_{12}(t) \\ \dots \dots \dots \dots \dots \dots \dots \\ h_{1n} = s_{1(n-1)}(t) - m_{1n}(t) \end{cases} \quad (5.11)$$

olduğunda

$$\begin{cases} s_{11} = h_{11}(t) / a_{11}(t) \\ s_{12} = h_{12}(t) / a_{12}(t) \\ \dots \dots \dots \dots \dots \dots \dots \\ s_{1n} = h_{1n}(t) / a_{1n}(t) \end{cases} \quad (5.12)$$

Anlık genliğe karşılık gelen fonksiyonu şu şekilde yazılır:

$$a_1(t) = a_{11}(t) a_{12}(t) \dots a_{1n}(t) \quad (5.13)$$

Anlık faz ve anlık frekansa karşılık gelen hesaplama ise:

$$\varphi_1(t) = \arccos(s_{1n}(t)) \quad (5.14)$$

$$f_1(t) = \frac{f_s d\varphi_1(t)}{2\pi dt} \quad (5.15)$$

İlk product fonksiyonu (PF) verilir;

$$PF_1(t) = a_1(t)s_{1n}(t) \quad (5.16)$$

4. adım: Yeni bir fonksiyon  $u_1(t)$  oluşturmak için ilk üretim fonksiyonu (PF, Production function)  $PF_1(t)$ 'yi orijinal sinyalden  $X(t)$  çıkartılır. Böylece,  $u_1(t)$  yeni bir sinyal olarak kabul edilir ve 1–3 adımları hiçbir salınım olmayana kadar ard arda tekrar edilir.

$$\begin{cases} u_1(t) = X(t) - PF_1(t) \\ u_2(t) = u_1(t) - PF_2(t) \\ \dots \dots \dots \dots \dots \dots \dots \dots \\ u_m(t) = u_{m-1}(t) - PF_m(t) \end{cases} \quad (5.17)$$

Son olarak, orijinal sinyal şu şekilde yeniden yapılandırılır:

$$x(t) = \sum_{i=1}^m PF_i(t) + u_m(t) \quad (5.18)$$

### 5.3 Hurst Üstel Katsayısı

Yeniden ölçeklendirilmiş aralık (R/S) analizi olarak da adlandırılan ve başlangıçta Hurst (1951) tarafından önerilen Hurst analizi, belirli bir zaman serisi için Hurst üsteli H'yi tahmin etmek ve sinyallerin stokastik davranışlarını analiz etmek için kullanılabilir. Mandelbrot ve Van Ness'in (1968) fraksiyonel Brownian hareketi ile resmen ilişkili olduğu Hurst üssü, fraktal eğrilerin kendine benzerliği olarak tanımlanabilir. Bu tez çalışmasında, Hurst analizi, ayırıştırılmadan sonra rüzgar enerjisinin farklı zaman-frekans bileşenlerinin davranışlarını karakterize etmek için kullanılmıştır. Belirli bir zaman serisi  $u(t)$  için, Hurst üssü aşağıdaki adımlar (Zhang ve Li, 2009) ile hesaplanır:

- 1- Seriler, "alt-periyotlar" denilen T uzunluğundaki N aralıklarına bölünür.
- 2- Her alt periyot için k,
  - (a) Bu alt periyotların ortalama ve standart sapması hesaplanır

$$\tilde{u}_k = \frac{1}{T} \sum_{t=t_k}^{t_k+T} u(t) \quad (5.19)$$

$$S_k = \left[ \frac{1}{T} \sum_{t=t_k}^{t_k+T} (u(t) - \bar{u}_k)^2 \right]^{1/2} \quad (5.20)$$

(b) Ortalama değerden sapma serisinin kümülatif toplamı hesaplanır;

$$U_k(t) = \sum_{t=t_k}^{t_k+T} (u(t) - \bar{u}_k) \quad (5.21)$$

(c) Alt periyot aralığı hesaplanır:

$$R_k = \max U_k(t) - \min U_k(t) \quad (5.22)$$

(d) Her alt periyot k için yeniden ölçeklendirilmiş aralıkları  $(R/S)_k$  hesaplanır:

$$(R/S)_k = \frac{R_k}{S_k} \quad (5.23)$$

3- Tüm N alt dönemleri için elde edilen ortalama  $(R/S)_k$  değerleri:

$$(R/S)_T = \frac{1}{N} \sum_{k=1}^N (R/S)_k \quad (5.24)$$

$(R/S)_T$ 'nin T ile açılımı alt-periyod uzunluğu T'nin çoklu değerleri için tekrarlanmasıyla elde edilebilir.  $(R/S)_T$  ve T arasında bir güç-fonksiyon ilişkisi sergiler:

$$(R/S)_T \sim T^H \quad (5.25)$$

H, Hurst üssüdür. Böylece, Hurst üssü aşağıdaki denklem kullanılarak tahmin edilir:

$$H = d[\ln(R/S)_T] / d[\ln(T)] \quad (5.26)$$

Kendine benzeyen zaman serileri için, Hurst üssü H ile kendi kendine benzer fraktal boyut D arasındaki ilişki şu şekilde ifade edilebilir (Chang ve ark., 2012; Rehman ve Siddiqi, 2009; Chen ve ark., 2008):



$$D = 2 - H \quad (5.27)$$

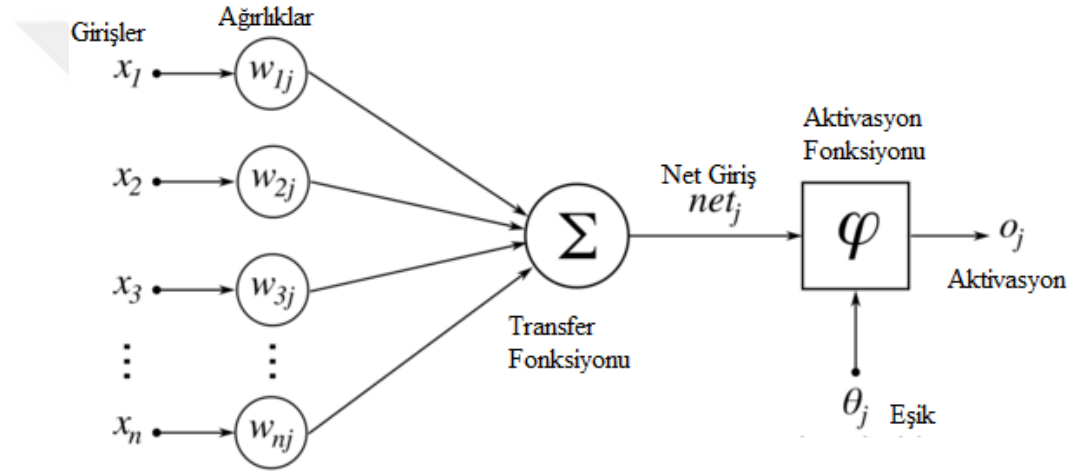
Hurst üssü 0 ile 1 arasında değişir. Fraktal teoriye göre, Hurst üssü 0 - 0,5 arasında ise serinin anti - kalıcı davranış sergilediğini, yani eğilimin gelecekte kendini tersine çevirme eğiliminde olduğunu gösteriyor. Hurst üssü 0,5 ise serinin davranışının tamamen rastgele olduğu ve geçmiş ve gelecekteki artışlar arasında tutarlı bir ilişki olmadığı anlamına gelir. 0,5 - 1 aralığındaki Hurst üssü serinin deterministik bir süreçle kalıcı davranış sergilediğini ve uzun vadeli korelasyonları gösterdiğini, yani uzun süre boyunca azalan veya artan bir eğilimin devam edeceğini gösterir (Liang ve ark., 2015). Bu çalışmada veriler Hurst üssünün 0.5'den küçük çıktığı durumlarda mikro, 0.5'ten büyük çıktığı durumlarda ise makro ölçekli gruplara ayrıldı. Gerek mevsimsel analizlerde gerekse haftalık analizlerde elde edilen veriler incelendiğinde meso grubunu oluşturmak için net olarak 0.5'e eşit Hurst katsayılarına rastlanmamaktadır. Bununla birlikte ayrıştırmalarda elde edilen katsayıların 0.5'e çok yakın olduğu değerler tespit edilmiştir. Bu nedenle çalışmada verilerden 0.5 değerinin  $\pm$  %5 aralığına karşılık gelenler meso grubuna dahil edilerek incelenmiştir (Liang ve ark., 2015).

#### 5.4 Geri Yayılımlı Sinir Ağı (BPNN, Back Propagation Neurol Network)

Bilgisayar teknolojisinin hızlı gelişimi son yıllarda istatistiksel modellerde artışa sebep olmuştur. Bu istatistiksel modellerden rüzgar hızı tahmini için en yaygın olarak kullanılan ve paralel işleme yapabilen Yapay Sinir Ağları (YSA)'dır. Bu modeller temel olarak geri yayılım (BP) (Guo ve ark., 2011), radyal temel işlevi (RBF) (Li ve Shi, 2010), Elman sinir ağı (ENN) (Jiang ve ark., 2017) ve dalgacık sinir ağı (WNN) (Xiao ve ark., 2017) ve diğerlerini içerir. Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahip sistemlerdir. Şekil 5.4'te gösterilen yapay sinir ağı hücresi, YSA'nın çalışmasında çok önemli küçük ve temel bilgi işleme birimidir Ağ içerisinde yer alan bütün nöronlar bir veya birden fazla girdi alırlar ve tek bir çıktı verirler. Bu çıktı başka nöronlara girdi olarak veya yapay sinir ağının dışına verilen çıktı olarak kullanılabilirler. Geliştirilen hücre modellerinde bazı farklılıklar olmakla birlikte genel özellikleri ile bir yapay hücre modeli 5 bileşenden oluşmaktadır (Özpinar, 2007) Bunlar;

- Girdi ve Girdirler
- Ağırlıklar
- Birleştirme Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktı

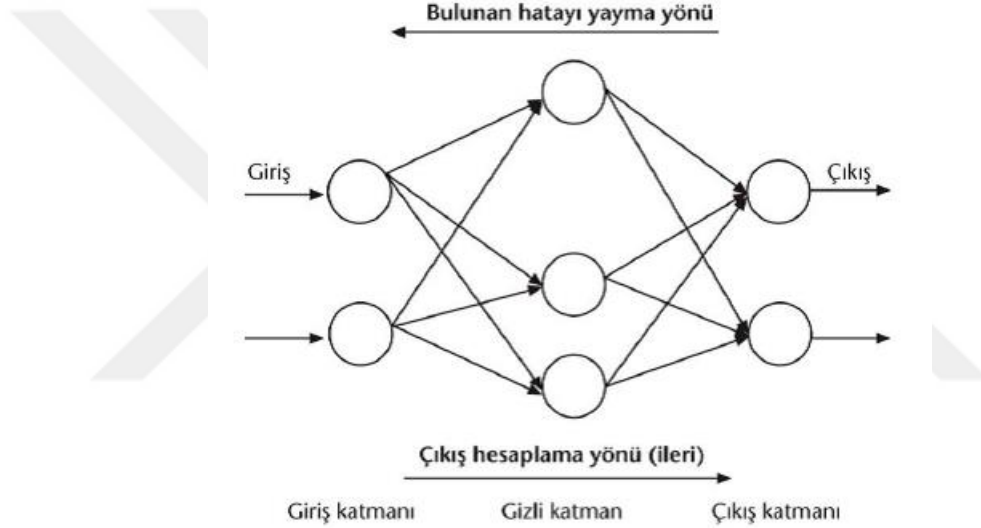
Farklı ağ yapılarının rüzgar hızı tahminlemede farklı performanslar gösterdiği bilinmektedir (Ramasamy ve ark, 2015).



Şekil 5.4. Temel Yapay Sinir Ağı Hücresi (Öztürk ve Şahin, 2018)

Şekil 5.4'te görüldüğü gibi bir hücreye n veri girişi yapılmaktadır. Buradaki W ağırlıklar matrisi, X ise girişler matrisidir. Girilen veriler ağırlıklarla çarpılarak tüm veriler toplanır ve transfer fonksiyonu işlemi sonucunda net girdi elde edilir. Net girdi aktivasyon fonksiyonundan geçirilir ve bir veri çıktısı elde edilmiş olur. Transfer fonksiyonlarında bir ağırlık eğitilmesi için veriler üzerinde işlem yapacak en uygun ağırlık değer seçimi önemlidir. Aktivasyon fonksiyonu, transfer fonksiyonundaki net girdi verilerini işlemek üzere bir fonksiyon olup net çıktı sonuçlarına ulaşır. Bu fonksiyon çoğunlukla doğrusal değildir. Her iki fonksiyonun doğru belirlenmesi önemlidir. Çünkü elde edilecek sonuç performansını belirleyecektir. Bazı aktivasyon fonksiyonları; Parçalı doğrusal fonksiyon, Hiperbolik tanjant aktivasyon fonksiyonu, Adımsal aktivasyon fonksiyonu gibidir (Öztürk ve Şahin., 2018).

En basit ve en genel yapay sinir ağı tek yönlü kullanılırlar. Yapay sinir ağı modelleri temel olarak iki grup (ileri ve geri beslemeli) olarak incelenmektedir. İleri beslemeli yapay sinir ağlarında gecikmeler yoktur, işlem girişlerden çıkışlara doğru ilerler. Çıkış değerleri, öğreticiden alınan hedeflenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilmekte ve ağırlıklar güncellenmektedir. Geri beslemeli yapay sinir ağlarında (Şekil 5.5) ise gecikmeler söz konusudur. Geri beslemeli Yapay Sinir ağı, elde edilen çıkışların tekrar girişlere bağlanarak oluşturulan bir ağıdır. Ağın  $t$  anındaki çıkışı  $o(t)$  ise,  $t + \Delta$  anındaki çıkışı ise  $o(t + \Delta)$ 'dır. Buradaki  $\Delta$  sabiti sembolik anlamda gecikme süresidir.



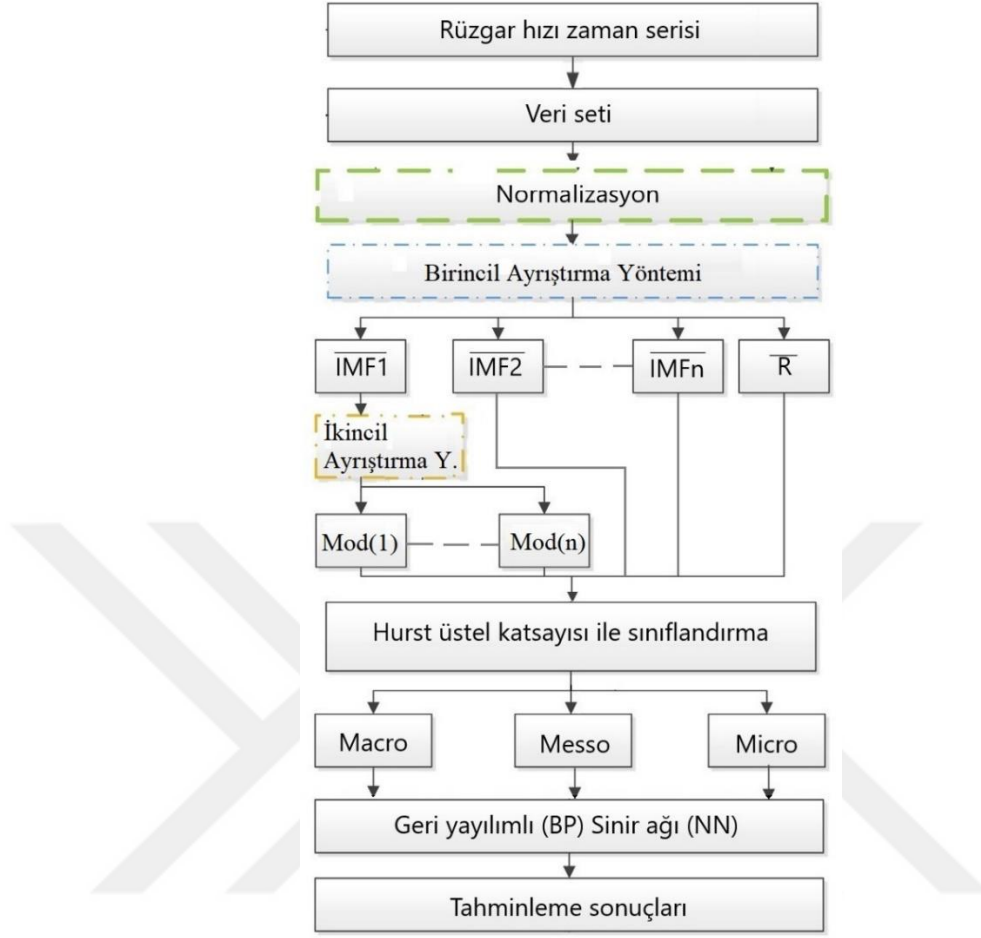
Şekil 5.5. Geri Beslemeli YSA (Kabalıcı, 2014)

Literatürde öğrenme sürecinin birçok yöntemi vardır. Yapay sinir ağları öğrenme algoritmalarına göre danışmanlı, danışmansız ve takviyeli öğrenme olarak üçe ayrılır. Danışmanlı öğrenme sırasında ağa verilen giriş değerleri ile aynı zamanda çıktı değerleri de verilir. Ağ verilen girdiler için istenen çıktıları oluşturabilmek için kendi ağırlıklarını günceller. Ağı çıktılar ile beklenen çıktılar arasındaki hata hesaplanarak ağın yeni ağırlıkları bu hata payına göre düzenlenir. Hata payı hesaplanırken ağın bütün çıktıları ile beklenen çıktıları arasındaki fark hesaplanır ve bu farka göre her hücreye düşen hata payı bulunur. Sonrasında her bir hücrenin kendisine denk gelen ağırlıkları günceller. Danışmansız öğrenmede ağa öğrenme sırasında sadece örnek girdiler verilmektedir. Herhangi bir beklenen çıktı bilgisi verilmez. Girişte verilen bilgilere göre ağ her bir örneği

kendi arasında sınıflandıracak şekilde kendi kurallarını oluşturur. Ağ bağlantı ağırlıklarını aynı özellikte olan dokuları ayırabilecek şekilde düzenleyerek öğrenme işlemini tamamlar. Takviyeli öğrenmede ise ağın her işlemi sonucunda elde ettiği sonuçların iyi veya kötü olup olmadığına dair bir bilgi verilir. Ağ bu bilgilere göre kendini yeniden düzenler. Bu sayede ağ herhangi bir girdi dizisiyle hem öğrenerek hem de sonuç çıkararak işlemeye devam eder (Çayıroğlu, 2018). Çalışmamızda YSA'nın en popüler öğrenme algoritması olan Geri Yayınım Algoritması ve Levenberg–Marquardt öğrenme algoritmaları kullanılmıştır. Geri yayınım algoritmasının öğrenmede kullanılan en genel algoritma olması ve bunun yanında basit ve iyi bir öğrenme kapasitesine sahip olması çalışmada tercih edilmesinin başlıca sebeplerini oluşturmaktadır. Bu sayede kendisine literatürde birçok uygulanma alanı bulmuştur (Özpınar, 2007)

## **5.5 Hibrit Modelin Uygulama Prosedürleri**

Hibrit CEEMDAN-LMD-Hurst-BPNN modelinin genel çerçevesi Şekil 6.1'de gösterilmektedir. Şekil 5.6'da gösterildiği gibi, hibrit modelin ana yapısı hibrit ayrıştırma ve Hurst–BPNN mekanizmasına dayanır. Önerilen modelin ayrıntılı adımları aşağıda açıklanmıştır:



Şekil 5.6. Çalışmada kullanılan hibrit modelin ana yapısı

1-Kurulan ölçüm istasyonundan toplanan rüzgar hızı verileri mevsimsel ve haftalık olarak gruplandırılır ve her bir grup içindeki veriler, sinir ağına kullanılmak üzere kümelerine ayrılır.

2-Veriler ayrıştırma ve tahminleme işlemi öncesinde normalizasyon işlemine tabi tutulur.

3-İlk aşamada, orijinal normalize rüzgar hızı serisi CEEMDAN ile artık bir (R) sinyaline kadar birkaç içsel mod fonksiyonları elde edilecek şekilde ayrıştırılır.

4-IMF1, IMF'ler arasında en düzensiz ve sistematik olmayan kısımdır. Bu durum tahmin zorluğunu artırmaktadır. Bu etkiyi azaltmak için IMF1, LMD kullanılarak ikincil ayrıştırma işlemine tabi tutulur.

5-Birincil ve ikincil ayrıştırma sonrasında elde edilen IMF'ler hurst analizine tabi tutulur. IMF'ler analiz neticesinde elde edilen hurst üssü değerlerine göre macro, messo ve micro olarak adlandırılan alt gruplarda yeniden birleştirilir 1-5 arasındaki adımlar hem haftalık

hem de mevsimsel analiz verileri için ayrı ayrı tekrarlanmaktadır. Haftalık tahminleme için yapılan analizlerin yukarıdaki adımları içerdiği toplu gösterim Ek 1'de sunulmaktadır.

6-Herbir alt grup bağımsız olarak BPNN'ye girdi olarak kullanılır ve tüm kıyaslama işlemi (BP, CEEMDAN-BP, LMD-BP, CEEMDAN-LMD-BP) modelleri ve önerilen hibrit modelin üç tipik performans ölçütü açısından ( $R^2$ , RMSE, MAPE) birden beşe kadar çok adımlı tahminlemesi yapılarak gerçekleştirilir. Bununla birlikte geliştirilen hibrit ayırıştırma tekniğinin geniş perspektiften değerlendirilebilmesi için iki hibrit algoritma (EEMD-VDM-BPNN ve EEMD-EWT-BPNN) kullanılarak karşılaştırmalı bir çalışma da gerçekleştirilmiştir.

## 5.6 Performans Değerlendirme Kriterleri

Tahmin performansının genel tahmin doğruluğu yaygın olarak kullanılan üç genel hata değerlendirme endeksi determinasyon katsayısı ( $R^2$ , Determination Coefficient), ortalama mutlak hata yüzdesi (MAPE, Mean Absolute Percent Error) ve Ortalama Kareysel Hatanın Karekökü (RMSE, Root Mean Square Error) ile gerçekleştirildi. Bu endekslere ait denklemler aşağıdadır (Sun ve ark., 2018):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{x}_i)^2} \quad (5.28)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{x}_i}{y_i} \right| \quad (5.29)$$

$$R^2 = \left( \frac{\sum(xy) - \frac{(\sum x)(\sum y)}{n}}{\sqrt{\left[ \sum x^2 - \frac{(\sum x)^2}{n} \right] \left[ \sum y^2 - \frac{(\sum y)^2}{n} \right]}} \right)^2 \quad (5.30)$$

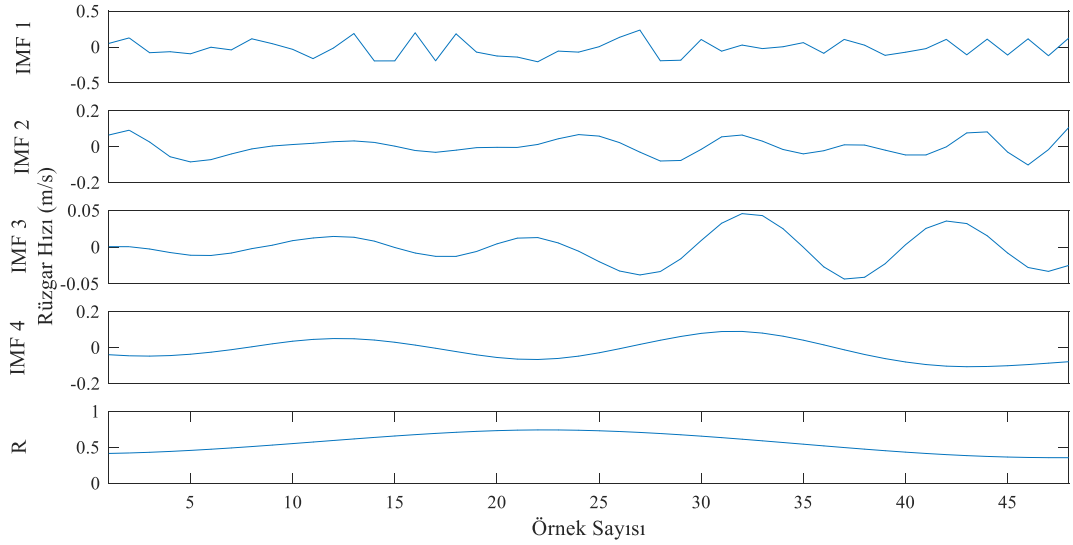
Denklemlerdeki  $y_i$  ve  $\hat{x}_i$  sırasıyla gözlenen ve tahmin edilen rüzgar hızını, N, toplam örnek sayısını temsil etmektedir.

## 6. ARAŞTIRMA BULGULARI ve TARTIŞMA

Tez çalışmasında, rüzgar hızı tahminlemesi için önerilen yenilikçi hibrit model 3 vaka çalışmasında kullanılarak değerlendirilmiştir. Birinci vaka çalışmasında haftalık, ikinci vaka çalışmasında mevsimsel rüzgar hızı verileri kullanılarak rüzgar hızı tahminlemesi gerçekleştirilmiş ve üçüncü vaka çalışmasında literatürde yer alan farklı hibrit tahminleme modelleri ile performans kıyaslaması yapılmıştır.


### 6.1 Vaka 1

Ölçüm istasyonundan toplanan haftalık rüzgar hızı verilerinin değişimi Şekil 5.3'te gösterilmiştir. Haftalık rüzgar hızı verilerine normalizasyon işlemi uygulandıktan sonra birincil ayrıştırma yöntemi olarak seçilen CEEMDAN tekniği ile IMF'lerine ayrıştırılmıştır (Şekil 6.1).




Şekil 6.1. Haftalık veriye ait CEEMDAN tekniği sonrası elde edilen IMFler

Elde edilen ilk IMF1, ana veriye en yakın alt veri seti olduğundan dolayı ikincil ayrıştırma yöntemi olan LMD tekniği IMF1 üzerinden tekrar edilmiştir (Şekil 6.2).



Şekil 6.2. Haftalık veriye ait LMD kullanılarak ayrıştırılmış IMF1 serisi.

Elde edilen tüm alt veri setleri (IMF – LMD) kümeleme işlemi için Hurst analizi işlemine tabi tutulmuştur. Analiz sonuçları Şekil 6.3'te gösterilmektedir. Eşitlik 5.25'te gösterilen  $\ln(R/S)$  ve  $\ln(T)$ 'ye göre eğrilerinin IMF1 ve LMD1 bileşenleri için ağırlıklı olarak doğrusal olmayan bir ilişki gösterdiği ve IMF2 – IMF5 ve LMD2 – LMD4 bileşenleri içinse kısmen doğrusal ilişkiler gösterdiği açıktır.



Şekil 6.3. Haftalık veriye ait çeşitli bileşenlerin hurst analizi

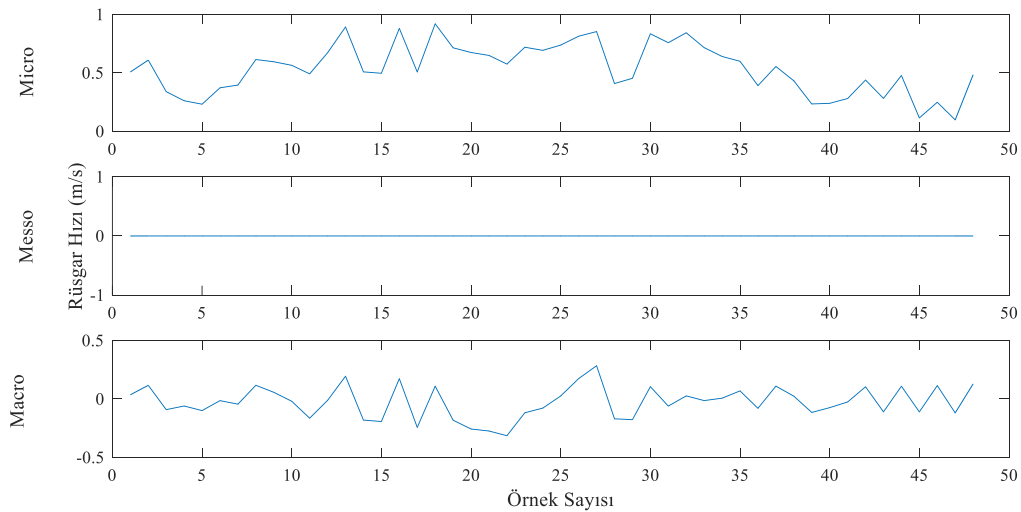


Eğrilerin yerleştirilmesiyle elde edilen Hurst üsleri ve eşitlik (5.27) kullanılarak elde edilen bileşenlerin fraktal boyutları Çizelge 6.1'de gösterilmektedir.

Çizelge 6.1. Haftalık veriye ait Hurst üstel katsayısı

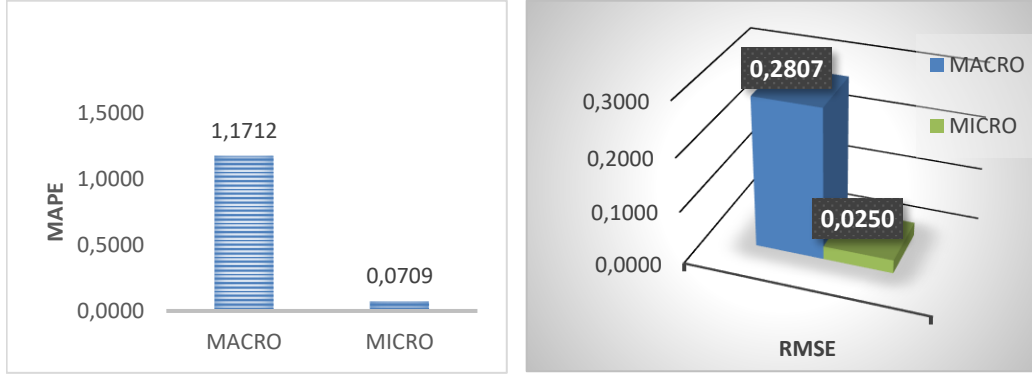
	IMF1	IMF2	IMF3	IMF4	R	LMD1	LMD2	LMD3	LMD4
H	0,9797	0,38889	0,38148	0,37761	0,37096	0,39252	0,98673	0,99296	0,99978
D	1,0203	1,61111	1,61852	1,62239	1,62904	1,60748	1,01327	1,00704	1,00022

Şekil 6.3 incelendiğinde IMF1, LMD2, LMD3 ve LMD4 bileşenleri fraktal karakteristik sergiler ve Hurst üsleri 0.5'ten büyük olduğu için kalıcı dinamik davranışını ile rüzgar gücünün bu bileşenlerinin makro dinamik kararlılığını yansıtır. IMF2, IMF3, IMF4, R ve LMD1 bileşenleri ise 0,5'ten küçük olması, rastgele hareket modeli sergilediği anlamına gelmektedir. Bununla birlikte 0.5'ten düşük değere sahip olması, anti-kalıcı davranışı yansıtır. Farklı ölçekleri temsil eden üç alt dizinin farklı bileşenleri, fraktal özelliklerine dayanarak üst üste getirilir ve yeniden oluşturulur. Spesifik olarak, IMF2, IMF3, IMF4, R ve LMD1 mikro ölçekli alt diziyi oluşturmak üzere birleştirilirken IMF1, LMD2, LMD3 ve LMD4 makro ölçeğinin alt grubunu oluşturmak için birleştirilir. Elde edilen sonuçlarda meso ölçekli bir değere sahip bileşene rastlanmamıştır. Elde edilen üç ölçek dizisinin değişimi Şekil 6.4'te gösterilmiştir.

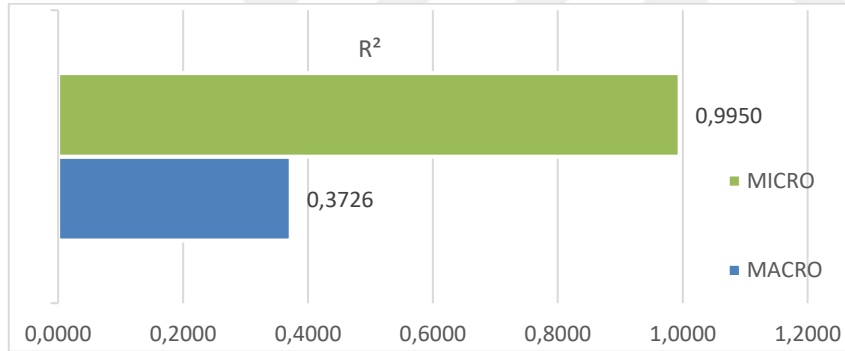


Şekil 6.4. Haftalık veriye ait üç alt kümede gruplandırılan verilerin değişimi

Micro ve macro, ayrı ayrı geri yayımlı sinir ağında tahminleme işlemine tabi tutulur. Şekil 6.5.a, b ve c’de macro ve micro verilerinin tahmin sonucu hata performansları karşılaştırılmıştır.



Şekil 6.5.a) Haftalık veriye ait MAPE Hata değeri b) Haftalık veriye ait RMSE hata değeri



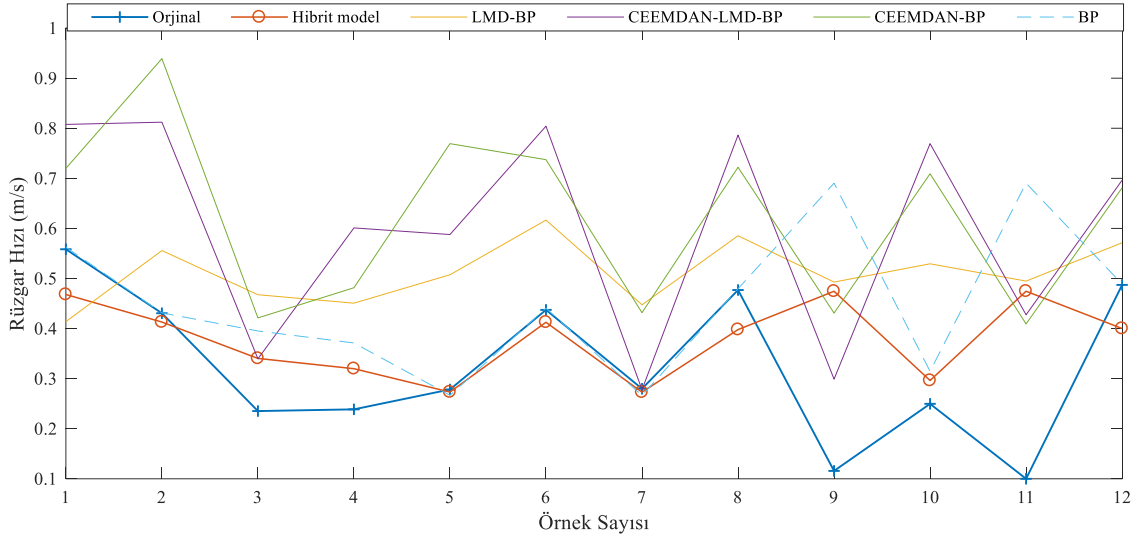
Şekil 6.5.c) Haftalık veriye ait R<sup>2</sup> Hata değeri

Şekil 6.5’te görüldüğü üzere micro veri seti baskın özellik göstermektedir. Dolayısıyla önerilen modelin kendi içerisindeki karşılaştırmasında micro veri seti dikkate alınmaktadır. Sahip olduğu özellikler, rüzgar hızı karakteristiği ile de örtüşmektedir. Çizelge 6.2’de, tüm alt grupların bağımsız olarak BPNN’e uygulanması sonucu elde edilen analizlerin performans değerlendirmesi (RMSE, MAPE ve R<sup>2</sup>) gösterilmiştir.

Çizelge 6.2. Haftalık veriye ait tahmin modellerinin performansları

Tahmin	Metrikler	CEEMDAN-LMD-BP	CEEMDAN-BP	LMD-BP	BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	1,5634	1,0103	1,0970	1,0399	<b>0,7053</b>
	R <sup>2</sup>	-0,2675	0,3828	0,4825	0,5180	<b>0,7931</b>
	RMSE	0,3573	0,2774	0,2524	0,2460	<b>0,1612</b>
Adım 2	MAPE	1,3538	1,4008	1,7449	0,4424	<b>0,1105</b>
	R <sup>2</sup>	0,2080	-0,2126	-0,344	0,9068	<b>0,9725</b>
	RMSE	0,3030	0,3440	0,4030	0,1082	<b>0,0587</b>
Adım 3	MAPE	1,3502	0,8975	2,0834	0,6485	<b>0,3969</b>
	R <sup>2</sup>	0,1607	0,5558	-0,984	0,8094	<b>0,9252</b>
	RMSE	0,3094	0,2260	0,4769	0,1547	<b>0,0969</b>
Adım 4	MAPE	1,1731	1,0850	1,0502	0,1645	<b>0,0709</b>
	R <sup>2</sup>	0,3558	0,3503	0,4356	0,9891	<b>0,9950</b>
	RMSE	0,2743	0,2805	0,2638	0,0369	<b>0,0250</b>
Adım 5	MAPE	1,3470	1,5995	1,6753	0,3879	<b>0,3026</b>
	R <sup>2</sup>	0,1644	-0,5885	-0,270	0,9315	<b>0,9488</b>
	RMSE	0,3148	0,3792	0,3875	0,0928	<b>0,0802</b>


Çizelge 6.2 incelendiğinde birinci adımdan beşinci adıma kadar yapılan tahminlerde önerdiğimiz hibrit modelin, tüm metriklerde en iyi sonucu verdiği görülmektedir. 4. adım tahminleme metrikleri diğer adımlara göre en iyi hassasiyete sahiptir. Bununla birlikte önerdiğimiz modelin hata oranının diğerlerine göre de tüm adımlarda düşük olduğunu görülmektedir. Şekil 6.6'da haftalık tahmin sonuçlarının grafiksel gösterimi yapılmıştır. Hibrit modelin orijinal veriyle en çok örtüşen veri seti olduğu gözlemlenmiştir.



Şekil 6.6. Haftalık tahmin sonuçlarının grafiksel gösterimi


## 6.2 Vaka 2

Vaka 1'deki işlem basamaklarının benzeri vaka 2'de de gerçekleştirilmiştir. Burada veri seti olarak veriler mevsimlere ayrılarak gruplandırılmıştır. Analizlerde İlkbahar (Şubat, Mart, Nisan), Yaz (Mayıs, Haziran, Temmuz), Sonbahar (Ağustos, Eylül, Ekim) ve Kış (Kasım, Aralık, Ocak) şeklinde her bir mevsim için 12.096 adet verinin bulunduğu çalışma seti düzenlenmiştir. Şekil 6.7'de kış mevsimine ait birincil ayrıştırma sonucu daha yüksekte düşük frekansa doğru elde edilen IMF'ler görülmektedir.



Şekil 6.7. Kış mevsimine ait CEEMDAN tekniği sonrası elde edilen IMFler

Bu IMF'lerden yüksek frekansa sahip IMF1 üzerinden elde edilen LMD ayrıştırma sonuçları da Şekil 6.8'de görülmektedir.



Şekil 6.8. Kış mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi

Elde edilen tüm alt veri setleri (IMF – LMD) kümeleme işlemi için Hurst analizi işlemine tabi tutulur. Elde edilen Hurst üsleri ve eşitlik (5.27) kullanılarak elde edilen bileşenlerin fraktal boyutları Çizelge 6.3'de gösterilmektedir.

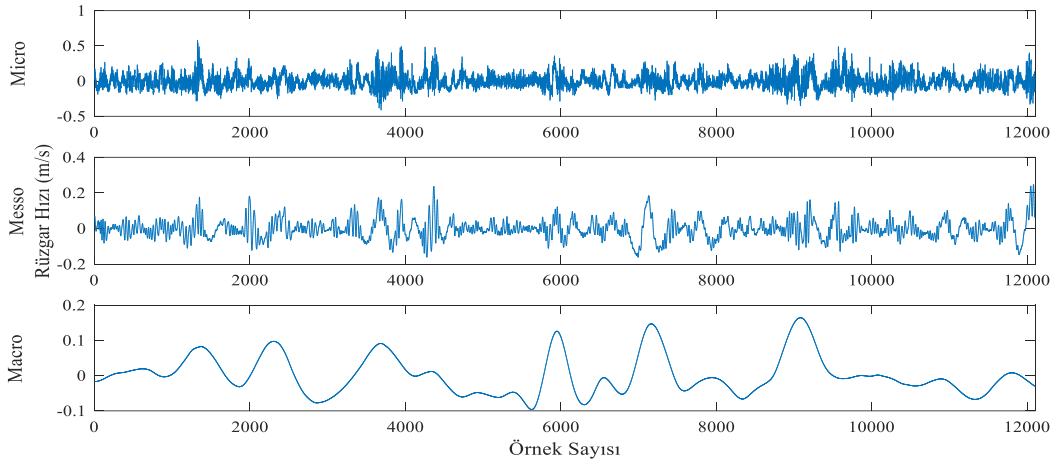
Çizelge 6.3. Kış mevsimine ait Hurst üstel katsayısı

	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5	IMF 6	IMF 7	IMF 8	IMF 9
H	0,4066	0,3656	0,2974	0,4084	0,4999	0,4024	0,4174	0,4911	0,4147
D	1,5934	1,6344	1,7026	1,5916	1,5001	1,5976	1,5826	1,5089	1,5853

	IMF 10	IMF 11	IMF 12	IMF 13	R	LMD 1	LMD 2	LMD 3	LMD 4
H	0,6132	0,6750	0,6899	0,9419	1,0126	0,3373	0,4217	0,4802	0,7357
D	1,3868	1,3250	1,3101	1,0581	0,9874	1,6627	1,5783	1,5198	1,2643


Çizelge 6.3 incelendiğinde IMF5, IMF8 ve LMD3 bileşenleri fraktal karakteristik sergiler ve Hurst üsleri de 0,5'e eşit değil ama yakındır bu nedenle bu rüzgar enerjisi zaman serisinin bu bileşenlerinin hafif anti-kalıcı davranışa rağmen daha çok rastgele yürüyüş modelleri sergilemekte ve serinin rassal bir trend izlemekte, başka bir ifadeyle normal bir dağılım sergilemektedir. IMF1 - IMF4, IMF6, IMF7, IMF9, LMD1 ve LMD2 bileşenleri 0,5'ten küçük olması, serinin uzun dönem hafıza etkisine sahip olmadığı ve rastgele hareket modeli sergilediği anlamına gelmektedir. Bununla birlikte anti-kalıcı davranışı

yansıtır. IMF10 - IMF13 ve LMD4 bileşenleri ise 0.5'ten büyük olduğu için uzun dönem hafıza etkisine sahiptir ve kalıcı dinamik davranışını ile rüzgar gücünün bu bileşenlerinin makro dinamik kararlılığını yansıtır. Farklı ölçekleri temsil eden üç alt dizinin farklı bileşenleri, fraktal özelliklerine dayanarak üst üste getirilir ve yeniden oluşturulur. R bileşeni 1'den büyük olduğu için fraktal özellik göstermediğinden dikkate alınmaz. Spesifik olarak, IMF1 - IMF4, IMF6, IMF7, IMF9, LMD1 ve LMD2 mikro ölçekli alt diziyi oluşturmak üzere birleştirilirken IMF10 - IMF13 ve LMD4 makro ölçeğinin alt grubunu oluşturmak için birleştirilir. Elde edilen sonuçlarda IMF5, IMF8 ve LMD3 meso ölçekli bir değere sahip alt bileşenleri oluşturmaktadır. Hurst analizi neticesinde macro, micro ve meso şeklinde gruplar oluşturulmaktadır. Şekil 6.9'da ise oluşan gruplar gösterilmiştir.




Şekil 6.9. Kış mevsimine ait üç alt kümede gruplandırılan verilerin değişimi

Kış mevsimi veri seti için Şekil 6.10.a, b ve c'de önerilen modele ait macro, meso ve micro verilerinin hata metrikleri gösterilmiştir.



Şekil 6.10.a) Kış mevsimine ait MAPE Hata değeri b) Kış mevsimine ait RMSE hata değeri



Şekil 6.10.c) Kış mevsimine ait R<sup>2</sup> Hata değeri


Çizelge 6.4'te ise kış mevsimine ait tüm tahmin modellerinin performans değerlendirmesi (RMSE, MAPE ve R<sup>2</sup>) karşılaştırılmıştır.



Çizelge 6.4 Kış mevsimi tahmin sonuçlarının karşılaştırılması

Tahmin	Metrikler	BP	LMD-BP	CEEMDAN-BP	CEEMDAN-LMD-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0.1990	0.3739	1,2850	0.4115	<b>0.0980</b>
	R <sup>2</sup>	0.9506	0.8080	0.4295	0.8280	<b>0.9999</b>
	RMSE	0.0615	0.1129	0.3625	0.1113	<b>0.0307</b>
Adım 2	MAPE	0.1964	0.7280	1,2920	0.4173	<b>0.0125</b>
	R <sup>2</sup>	0.9506	0.0857	0.1798	0.8156	<b>0.9998</b>
	RMSE	0.0615	0.1862	0.4297	0.1125	<b>0.0382</b>
Adım 3	MAPE	0.1981	5,7812	1,2124	0.4559	<b>0.0012</b>
	R <sup>2</sup>	0.9510	0.1321	0.4042	0.6829	<b>0.9998</b>
	RMSE	0.0613	1,2909	0.3235	0.1235	<b>0.0383</b>
Adım 4	MAPE	0.2037	0.3442	0.7378	0.5037	<b>0.0508</b>
	R <sup>2</sup>	0.9489	0.8715	0.0760	0.5226	<b>0.9999</b>
	RMSE	0.0626	0.0982	0.1926	0.1317	<b>0.0206</b>
Adım 5	MAPE	0.1995	0.7452	0.9579	0.3817	<b>0.0691</b>
	R <sup>2</sup>	0.9503	0.1698	0.2459	0.8471	<b>0.9995</b>
	RMSE	0.0617	0.1905	0.2816	0.1076	<b>0.0203</b>


Kış mevsim veri seti sonuçları Çizelge 6.4'te incelendiğinde, 5 adımlı tahminlemede önerilen hibrit model, en düşük RMSE 0.0203 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarının yüksek olduğunu göstermektedir. En yüksek R<sup>2</sup> değerine bakıldığında 0.9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0012 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Ayrıca tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve R<sup>2</sup>) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Şekil 6.11'de tahmin sonuçlarının grafiksel gösterimi sunulmuştur.




Şekil 6.11. Kış mevsimi tahmin sonuçlarının grafiksel

Şekil 6.11’de ise Hibrit model tahmin sonucu, diğer sonuçlara göre orijinal veri ile daha çok örtüşmektedir. Dolayısıyla hibrit modelimiz ile orijinal veriye yakın değerler ortaya konulmuştur.


Yaz mevsimi veri seti için Şekil 6.12’de, birincil ayrıştırma sonucu daha yüksekte düşük frekansa elde edilen IMF’ler görülmektedir.





Şekil 6.12. Yaz mevsimine ait CEEMDAN tekniği sonrası elde edilen IMFler

Bu IMF'lerden yüksek frekansa sahip IMF1 üzerinden elde edilen LMD ayrıştırma sonuçları Şekil 6.13'de gösterilmiştir.



Şekil 6.13. Yaz mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi

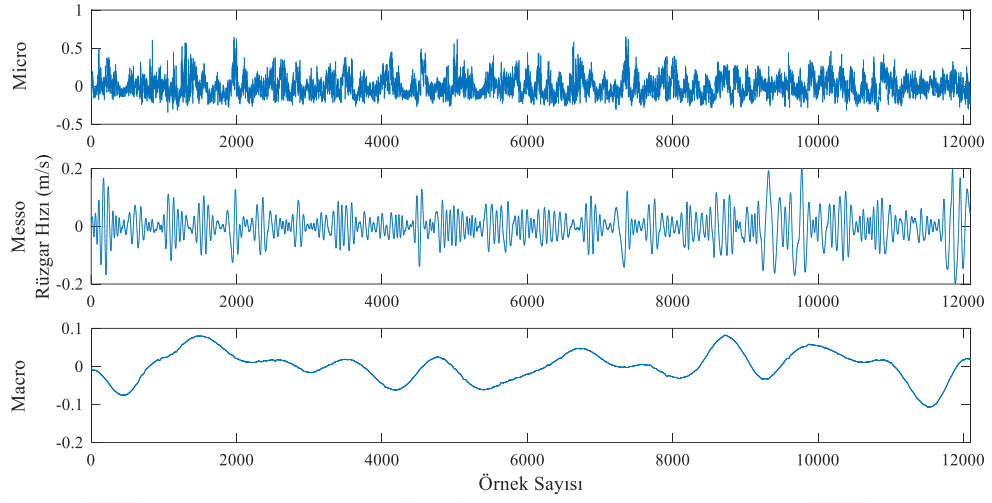
Elde edilen tüm alt veri setleri (IMF – LMD) kümeleme işlemi için Hurst analizi işlemine tabi tutulur. Elde edilen Hurst üsleri ve eşitlik (5.27) kullanılarak elde edilen bileşenlerin fraktal boyutları Çizelge 6.5'de gösterilmektedir.

Çizelge 6.5. Yaz mevsimine ait Hurst üstel katsayısı

	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5	IMF 6	IMF 7	IMF 8	IMF 9
H	0,3121	0,3467	0,3624	0,3692	0,3952	0,5156	0,4503	0,2721	0,4371
D	1,6879	1,6533	1,6376	1,6308	1,6048	1,4844	1,5497	1,7279	1,5629


	IMF 10	IMF 11	IMF 12	IMF 13	R	LMD 1	LMD 2	LMD 3
H	0,5956	0,6916	0,8213	0,9777	1,0147	0,2878	0,3898	0,5587
D	1,4044	1,3084	1,1787	1,0223	0,9853	1,7122	1,6102	1,4413

Çizelge 6.5 incelendiğinde IMF6 ve IMF7 bileşeri fraktal karakteristik sergiler ve Hurst üsleri de 0,5'e eşit değil ama yakındır bu nedenle bu rüzgar enerjisi zaman serisinin bu bileşenin hafif anti-kalıcı davranış olmasına rağmen daha çok rastgele yürüyüş modelleri sergilemekte ve serinin rassal bir trend izlemekte, başka bir ifadeyle normal bir dağılım sergilemektedir. IMF1 – IMF5, IMF8, IMF9, LMD1 ve LMD2 bileşenleri 0,5'ten küçük olması, serinin uzun dönem hafıza etkisine sahip olmadığı ve rastgele hareket modeli sergilediği anlamına gelmektedir. Bununla birlikte anti-kalıcı davranışı yansıtır. IMF10 - IMF13 ve LMD3 bileşenleri ise 0.5'ten büyük olduğu için uzun dönem hafıza etkisine sahiptir ve kalıcı dinamik davranışını ile rüzgar gücünün bu bileşenlerinin makro dinamik kararlılığını yansıtır. Farklı ölçekleri temsil eden üç alt dizinin farklı bileşenleri, fraktal özelliklerine dayanarak üst üste getirilir ve yeniden oluşturulur. R bileşeni 1'den büyük olduğu için fraktal özellik göstermediğinden dikkate alınmaz. Spesifik olarak, IMF1 – IMF5, IMF8, IMF9, LMD1 ve LMD2 mikro ölçekli alt diziyi oluşturmak üzere birleştirilirken IMF10 - IMF13 ve LMD3 makro ölçeğinin alt grubunu oluşturmak için birleştirilir. Elde edilen sonuçlarda IMF6 ve IMF7 meso ölçekli bir değere sahip alt bileşeni oluşturmaktadır. Hurst analizi neticesinde macro, micro ve meso oluşturulmaktadır. Şekil 6.14'de oluşan gruplar gösterilmiştir.




Şekil 6.14. Yaz mevsimine ait üç alt kümede gruplandırılan verilerin değişimi

Yaz mevsimi veri seti için Şekil 6.15.a, b ve c'de önerilen modele ait macro, meso ve micro verilerinin hata metrikleri gösterilmiştir.



Şekil 6.15.a) Yaz mevsimine ait MAPE Hata değeri b) RMSE hata değeri




Şekil 6.15.c) Yaz mevsimine ait R<sup>2</sup> Hata değeri

Çizelge 6.6'te ise yaz mevsimi için tüm tahmin modellerinin performans değerlendirmesi (RMSE, MAPE ve  $R^2$ ) karşılaştırılmıştır.

Çizelge 6.6. Yaz mevsimi tahmin sonuçlarının karşılaştırılması

Tahmin	Metrikler	BP	LMD-BP	CEEMDAN-BP	CEEMDAN-LMD-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0.2245	0.6235	0.4047	0.4607	<b>0.0115</b>
	$R^2$	0.9430	0.3956	0.8330	0.7102	<b>0.9999</b>
	RMSE	0.0872	0.2123	0.1475	0.1703	<b>0.0403</b>
Adım 2	MAPE	0.2241	0.6405	0.4063	0.4876	<b>0.0887</b>
	$R^2$	0.9430	0.2532	0.8282	0.6085	<b>0.9992</b>
	RMSE	0.0872	0.2237	0.1489	0.1813	<b>0.0322</b>
Adım 3	MAPE	0.2240	0.1457	0.4017	0.4630	<b>0.0801</b>
	$R^2$	0.9432	-0.3261	0.8394	0.7194	<b>0.9992</b>
	RMSE	0.0871	0.4510	0.1455	0.1703	<b>0.0319</b>
Adım 4	MAPE	0.2240	0.2024	0.4117	0.4468	<b>0.0952</b>
	$R^2$	0.9428	-0.9344	0.8063	0.7787	<b>0.9998</b>
	RMSE	0.0873	0.6108	0.1545	0.1637	<b>0.0377</b>
Adım 5	MAPE	0.2239	0.1504	0.4103	0.5302	<b>0.0539</b>
	$R^2$	0.9431	-0.2935	0.8187	0.3211	<b>0.9995</b>
	RMSE	0.0872	0.4856	0.1512	0.1962	<b>0.0270</b>


Yaz mevsim veri seti sonuçları Çizelge 6.6 incelendiğinde önerilen hibrit model, en düşük RMSE 0,0270 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir. En yüksek  $R^2$  değerine bakıldığında 0,9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0,0115 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Ayrıca tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve  $R^2$ ) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Şekil 6.16'da tahmin sonuçlarının grafiksel gösterimi sunulmuştur.




Şekil 6.16. Yaz mevsimi tahmin sonuçlarının grafiksel gösterimi

Şekil 6.16’te Hibrit modelin tahmin sonucu, diğer sonuçlara göre orijinal veri ile daha çok örtüşmektedir. Dolayısıyla hibrit model, orijinal veriyle aynı değerler göstermektedir.


İlkbahar mevsimi veri seti için Şekil 6.17’de ilkbahar mevsimine ait birincil ayrıştırma sonucu daha yüksekten düşük frekansa sahip IMF’ler gösterilmektedir.





Şekil 6.17. İlkbahar mevsimine ait CEEMDAN tekniği ile elde edilen IMFler

Bu IMF'lerden yüksek frekansa sahip IMF1 verisi üzerinden elde edilen LMD ayrıştırma sonuçları Şekil 6.18'de görülmektedir.



Şekil 6.18. İlkbahar mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi

Elde edilen ilkbahar mevsimine ait tüm alt veri setleri (IMF – LMD) kümeleme işlemi için Hurst analizi işlemine tabi tutulur. Elde edilen Hurst üsleri ve eşitlik (5.27) kullanılarak elde edilen bileşenlerin fraktal boyutları Çizelge 6.7'de gösterilmektedir.




Çizelge 6.7. İlkbahar mevsimine ait Hurst üstel katsayısı

	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5	IMF 6	IMF 7	IMF 8	IMF 9
H	0,5707	0,4159	0,4344	0,3908	0,3818	0,4286	0,4895	0,3808	0,4224
D	1,4293	1,5841	1,5656	1,6092	1,6182	1,5714	1,5105	1,6192	1,5776


	IMF 10	IMF 11	IMF 12	R	LMD 1	LMD 2	LMD 3	LMD 4
H	0,5408	0,6209	0,8560	1,0106	0,5646	0,2738	0,4334	0,6620
D	1,4592	1,3791	1,1440	0,9894	1,4354	1,7262	1,5666	1,3380

Çizelge 6.7 incelendiğinde IMF7 ve IMF10 bileşleri fraktal karakteristik sergiler ve Hurst üsleri de 0,5'e eşit değil ama yakındırlar bu nedenle bu rüzgar enerjisi zaman serisinin bu bileşenleri, hafif anti-kalıcı davranış olmasına rağmen daha çok rastgele yürüyüş modelleri sergilemekte ve serinin rassal bir trend izlemekte, başka bir ifadeyle normal bir dağılım sergilemektedir. IMF2 – IMF6, IMF8, IMF9, LMD2 ve LMD3 bileşenleri 0,5'ten küçük olması, serinin uzun dönem hafıza etkisine sahip olmadığı ve rastgele hareket modeli sergilediği anlamına gelmektedir. Bununla birlikte anti-kalıcı davranışı yansıtır. IMF1, IMF11, IMF12, LMD1 ve LMD4 bileşenleri ise 0,5'ten büyük olduğu için uzun dönem hafıza etkisine sahiptir ve kalıcı dinamik davranışını ile rüzgar gücünün bu bileşenlerinin makro dinamik kararlılığını yansıtır. Farklı ölçekleri temsil eden üç alt dizinin farklı bileşenleri, fraktal özelliklerine dayanarak üst üste getirilir ve yeniden oluşturulur. R bileşeni 1'den büyük olduğu için fraktal özellik göstermediğinden dikkate alınmaz. Spesifik olarak, IMF2 – IMF6, IMF8, IMF9, LMD2 ve LMD3 mikro ölçekli alt diziyi oluşturmak üzere birleştirilirken IMF1, IMF11, IMF12, LMD1 ve LMD4 makro ölçeğinin alt grubunu oluşturmak için birleştirilir. Elde edilen sonuçlarda IMF7 ve IMF10 meso ölçekli bir değere sahip alt bileşeni oluşturmaktadır. Hurst analizi neticesinde macro, micro ve meso grupları oluşmaktadır. Şekil 6.19'da ise oluşan gruplar gösterilmiştir.




Şekil 6.19. İlkbahar mevsimine ait üç alt kümede gruplandırılan veriler

İlkbahar mevsimi veri seti için Şekil 6.20.a, b ve c'de önerilen modele ait macro, messo ve micro verilerinin hata metrikleri gösterilmiştir.



Şekil 6.20.a) İlkbahar ayına ait MAPE Hata değeri b) RMSE hata değeri



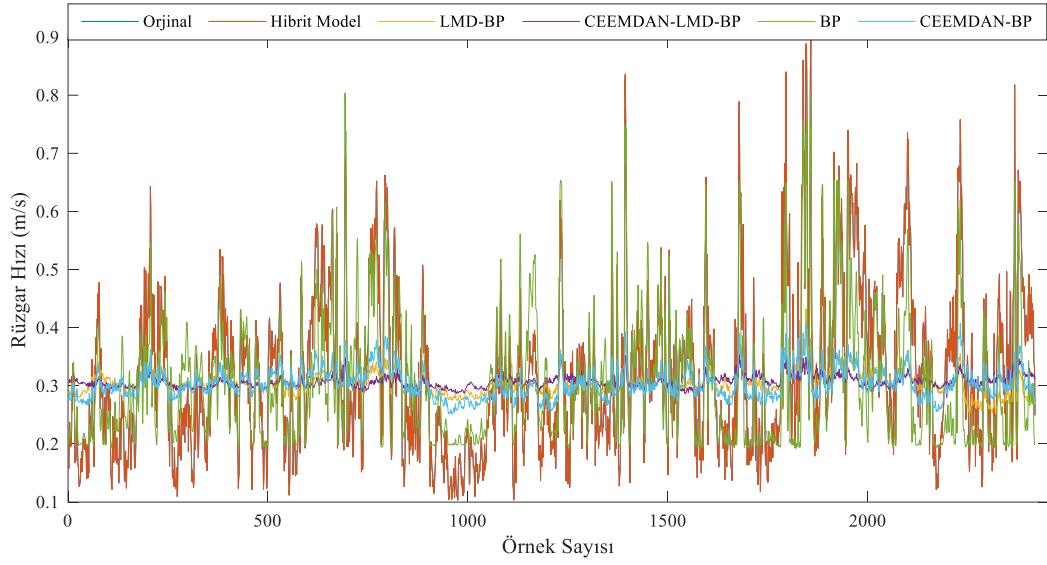
Şekil 6.20.c) İlkbahar mevsimine ait  $R^2$  Hata değeri

Çizelge 6.8’de ise tüm tahmin modellerinin performans değerlendirmesi (RMSE, MAPE ve  $R^2$ ) karşılaştırılmıştır.

Çizelge 6.8. İlkbahar mevsimi tahmin sonuçlarının karşılaştırılması


Tahmin	Metrikler	BP	LMD-BP	CEEMDAN-BP	CEEMDAN-LMD-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0.2088	0.3458	0.3583	0.3716	<b>0.0118</b>
	$R^2$	0.9459	0.8612	0.8640	0.8517	<b>0.9995</b>
	RMSE	0.0807	0.1281	0.1278	0.1334	<b>0.0130</b>
Adım 2	MAPE	0.2104	0.3749	0.3665	0.3742	<b>0.0600</b>
	$R^2$	0.9462	0.7993	0.8565	0.8507	<b>0.9999</b>
	RMSE	0.0804	0.1454	0.1309	0.1339	<b>0.0080</b>
Adım 3	MAPE	0.2103	0.3523	0.3683	0.5499	<b>0.0584</b>
	$R^2$	0.9460	0.8564	0.8562	-0.0225	<b>0.9999</b>
	RMSE	0.0806	0.1301	0.1310	0.1878	<b>0.0226</b>
Adım 4	MAPE	0.2092	0.4286	0.3550	0.3724	<b>0.0396</b>
	$R^2$	0.9462	0.6628	0.8652	0.8502	<b>0.9998</b>
	RMSE	0.0805	0.1674	0.1273	0.1340	<b>0.0316</b>
Adım 5	MAPE	0.2102	0.3451	0.3563	0.3731	<b>0.0352</b>
	$R^2$	0.9466	0.8396	0.8621	0.8505	<b>0.9999</b>
	RMSE	0.0802	0.1354	0.1287	0.1339	<b>0.0262</b>


İlkbahar mevsim veri seti sonuçları Çizelge 6.8’te incelendiğinde ilkbahar mevsim verisinde önerilen hibrit model, en düşük RMSE 0.0080 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir. En yüksek  $R^2$  değerine bakıldığında 0.9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0118 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Ayrıca tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve  $R^2$ ) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Şekil 6.21’de tahmin sonuçlarının grafiksel gösterimi sunulmuştur.



Şekil 6.21. İlkbahar mevsimi tahmin sonuçlarının grafiksel gösterimi


Şekil 6.21’da ise Hibrit model tahmin sonucu, diğer sonuçlara göre orijinal veri ile daha çok örtüşmektedir. Sonbahar veri setinde Şekil 6.22’de sonbahar mevsimine ait birincil ayrıştırma sonucu daha yüksekten düşük frekansa doğru elde edilen IMF’ler gösterilmiştir.





Şekil 6.22. Sonbahar mevsimine ait CEEMDAN tekniği ile elde edilen IMFler

Elde edilen IMF'lerden yüksek frekansa sahip IMF1 üzerinden elde edilen LMD ayrıştırma sonuçları Şekil 6.23'de görülmektedir.



Şekil 6.23. Sonbahar mevsimine ait LMD kullanılarak ayrıştırılmış IMF1 serisi


Elde edilen tüm alt veri setleri (IMF – LMD) kümeleme işlemi için Hurst analizi işlemine tabi tutulur. Elde edilen Hurst üsleri ve eşitlik (5.27) kullanılarak elde edilen bileşenlerin fraktal boyutları Çizelge 6.9'da gösterilmektedir.

Çizelge 6.9. Sonbahar mevsimine ait Hurst üstel katsayısı

	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5	IMF 6	IMF 7	IMF 8	IMF 9
H	0,3104	0,3345	0,3386	0,4301	0,3431	0,5031	0,2825	0,4721	0,5184
D	1,6896	1,6655	1,6614	1,5699	1,6569	1,4969	1,7175	1,5279	1,4816


	IMF 10	IMF 11	IMF 12	R	LMD 1	LMD 2	LMD 3	LMD 4
H	0,6228	0,6540	0,8120	1,0014	0,3182	0,4338	0,4762	0,6532
D	1,3772	1,3460	1,1880	0,9986	1,6818	1,5662	1,5238	1,3468

Çizelge 6.9 incelendiğinde IMF6, IMF8, IMF9 ve LMD3 bileşenleri fraktal karakteristik sergiler ve Hurst üsleri de 0,5'e eşit değil ama yakındır bu nedenle bu rüzgar enerjisi zaman serisinin bu bileşelerinin hafif anti-kalıcı davranış olmasına rağmen daha çok rastgele yürüyüş modelleri sergilemekte ve serinin rassal bir trend izlemekte, başka bir ifadeyle normal bir dağılım sergilemektedir. IMF1 – IMF5, IMF7, LMD1 ve LMD2 bileşenleri 0,5'ten küçük olması, serinin uzun dönem hafıza etkisine sahip olmadığı ve rastgele hareket modeli sergilediği anlamına gelmektedir. Bununla birlikte anti-kalıcı davranışı yansıtır. IMF10 - IMF12 ve LMD4 bileşenleri ise 0.5'ten büyük olduğu için uzun dönem hafıza etkisine sahiptir ve kalıcı dinamik davranışını ile rüzgar gücünün bu bileşenlerinin makro dinamik kararlılığını yansıtır. Farklı ölçekleri temsil eden üç alt dizinin farklı bileşenleri, fraktal özelliklerine dayanarak üst üste getirilir ve yeniden oluşturulur. R bileşeni 1'den büyük olduğu için fraktal özellik göstermediğinden dikkate alınmaz. Spesifik olarak IMF1 – IMF5, IMF7, LMD1 ve LMD2 mikro ölçekli alt diziyi oluşturmak üzere birleştirilirken IMF10 - IMF12 ve LMD4 makro ölçeğinin alt grubunu oluşturmak için birleştirilir. Elde edilen sonuçlarda IMF6, IMF8, IMF9 ve LMD3 ise meso ölçekli bir değere sahip alt bileşeni oluşturmaktadır. Hurst analizi neticesinde macro, micro ve meso grupları oluşturulmaktadır. Şekil 6.24'te oluşan gruplar gösterilmiştir.




Şekil 6.24. Sonbahar mevsimine ait üç alt kümede gruplandırılan veriler

Sonbahar mevsimi veri seti için Şekil 6.25.a, b ve c’de önerilen modele ait macro, messo ve micro verilerinin hata metrikleri gösterilmiştir.



Şekil 6.25.a) Sonbahar mevsimine ait MAPE Hata değeri b) RMSE hata değeri



Şekil 6.25.c) Sonbahar mevsimine ait  $R^2$  Hata değeri


Çizelge 6.10’da ise tüm tahmin modellerinin performans değerlendirmesi (RMSE, MAPE ve  $R^2$ ) karşılaştırılmıştır.

Çizelge 6.10. Sonbahar mevsimi tahmin sonuçlarının karşılaştırılması

Tahmin	Metrikler	BP	LMD-BP	CEEMDAN-BP	CEEMDAN-LMD-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0,3875	0,4259	0,9662	0,5032	<b>0,0580</b>
	$R^2$	0,8790	0,8524	-0,1811	0,7922	<b>0,9995</b>
	RMSE	0,0947	0,1042	0,2593	0,1207	<b>0,0189</b>
Adım 2	MAPE	0,3932	0,4457	0,1023	0,7256	<b>0,0130</b>
	$R^2$	0,8755	0,8482	-0,1802	-0,2755	<b>0,9996</b>
	RMSE	0,0961	0,1058	0,272	0,1745	<b>0,0319</b>
Adım 3	MAPE	0,3959	0,7781	0,1292	0,5053	<b>0,0885</b>
	$R^2$	0,8747	0,0905	0,1798	0,7856	<b>0,9992</b>
	RMSE	0,0964	0,1879	0,4297	0,1215	<b>0,0243</b>
Adım 4	MAPE	0,3970	0,4369	0,1212	0,5198	<b>0,0114</b>
	$R^2$	0,8744	0,8508	0,4042	0,7674	<b>0,9995</b>
	RMSE	0,0965	0,1049	0,3235	0,1254	<b>0,0333</b>
Adım 5	MAPE	0,3893	0,4775	0,7378	0,1088	<b>0,0174</b>
	$R^2$	0,8772	0,8305	0,0760	0,7077	<b>0,9997</b>
	RMSE	0,0954	0,1115	0,1926	0,2577	<b>0,0458</b>

Sonbahar mevsim veri seti sonuçları Çizelge 6.10’te incelendiğinde Sonbahar mevsim verisinde, önerilen hibrit model, en düşük RMSE 0.0189 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarının yüksek olduğunu göstermektedir. En yüksek  $R^2$  değerine bakıldığında 0.9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0114 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve  $R^2$ ) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Şekil 6.26’da tahmin sonuçlarının grafiksel gösterimi sunulmuştur.





Şekil 6.26. Sonbahar mevsimi tahmin sonuçlarının grafiksel gösterimi

Şekil 6.26’da ise Hibrit model tahmin sonucu, diğer sonuçlara göre orijinal veri ile daha çok örtüşmektedir.

### 6.3 Vaka 3

Vaka 3’te ise önerilen hibrit model literatürdeki yaygın kullanılan modellerden EEMD-VDM-BPNN ve EEMD-EWT-BPNN ile hem haftalık hemde mevsimsel olarak performans karşılaştırması işlemine tabi tutulmuştur. Önerilen hibrit model ile karşılaştırma modellerinden elde edilen sonuçlar Çizelge 6.11’de gösterilmektedir.

Çizelge 6.11. Haftalık veri seti üzerinden hibrit modellerin karşılaştırılması

Tahmin	Metrikler	EEMD-EWT-BP	EEMD-VDM-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	1,0612	1,4517	<b>0,7053</b>
	R <sup>2</sup>	0,4298	0,2165	<b>0,7931</b>
	RMSE	0,2676	0,3137	<b>0,1612</b>
Adım 2	MAPE	0,4382	1,3104	<b>0,1105</b>
	R <sup>2</sup>	0,9116	0,3612	<b>0,9725</b>
	RMSE	0,1054	0,2832	<b>0,0587</b>
Adım 3	MAPE	0,4837	1,3377	<b>0,3969</b>
	R <sup>2</sup>	0,8183	0,3348	<b>0,9252</b>
	RMSE	0,1511	0,2890	<b>0,0969</b>
Adım 4	MAPE	0,5074	1,3930	<b>0,0709</b>
	R <sup>2</sup>	0,8765	0,2790	<b>0,9950</b>
	RMSE	0,1245	0,3009	<b>0,0250</b>
Adım 5	MAPE	0,5143	1,4281	<b>0,3026</b>
	R <sup>2</sup>	0,8751	0,2420	<b>0,9488</b>
	RMSE	0,1253	0,3085	<b>0,0802</b>

Haftalık veri seti sonuçları Çizelge 6.11’de incelendiğinde, önerilen hibrit model, en düşük RMSE 0,0250 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir. En yüksek R<sup>2</sup> değerine bakıldığında 0,9950 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0709 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve R<sup>2</sup>) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Çizelge 6.12’de ilkbahar veri seti ile diğer modeller karşılaştırılmıştır.

Çizelge 6.12. İlkbahar veri seti üzerinden hibrit modellerin karşılaştırılması

Tahmin	Metrikler	EEMD-EWT-BP	EEMD-VDM-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0,3818	0,3712	<b>0.0011</b>
	R <sup>2</sup>	0,8376	0,8548	<b>0.9999</b>
	RMSE	0,1369	0,1317	<b>0.0130</b>
Adım 2	MAPE	0,3845	0,3901	<b>0.0657</b>
	R <sup>2</sup>	0,8399	0,8301	<b>0.9995</b>
	RMSE	0,1373	0,1376	<b>0.0882</b>
Adım 3	MAPE	0,3854	0,3745	<b>0.0005</b>
	R <sup>2</sup>	0,8314	0,8442	<b>0.9997</b>
	RMSE	0,1387	0,1345	<b>0.0226</b>
Adım 4	MAPE	0,3867	0,4223	<b>0.0396</b>
	R <sup>2</sup>	0,8287	0,7659	<b>0.9992</b>
	RMSE	0,1400	0,1504	<b>0.0316</b>
Adım 5	MAPE	0,3802	0,4783	<b>0.0352</b>
	R <sup>2</sup>	0,8200	0,5575	<b>0.9997</b>
	RMSE	0,1400	0,1679	<b>0.0262</b>

İlkbahar veri seti sonuçları Çizelge 6.12’de incelendiğinde, önerilen hibrit model, en düşük RMSE 0,0130 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarının yüksek olduğunu göstermektedir. En yüksek R<sup>2</sup> değerine bakıldığında 0,9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0,0005 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve R<sup>2</sup>) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Çizelge 6.13’te kış veri seti ile diğer modeller karşılaştırılmıştır.

Çizelge 6.13. Kış veri seti üzerinden hibrit modellerin karşılaştırılması

Tahmin	Metrikler	EEMD- EWT-BP	EEMD- VDM-BP	CEEMDAN-LMD- HURST-BP (Hibrit Model)
Adım 1	MAPE	0,3951	0,3910	<b>0,0985</b>
	R <sup>2</sup>	0,8473	0,8396	<b>0,9998</b>
	RMSE	0,1079	0,1099	<b>0,0307</b>
Adım 2	MAPE	0,3949	0,3916	<b>0,0125</b>
	R <sup>2</sup>	0,8474	0,8441	<b>0,9991</b>
	RMSE	0,1079	0,1088	<b>0,0382</b>
Adım 3	MAPE	0,3968	0,3947	<b>0,0127</b>
	R <sup>2</sup>	0,8491	0,8408	<b>0,9998</b>
	RMSE	0,1075	0,1097	<b>0,0382</b>
Adım 4	MAPE	0,3999	0,3904	<b>0,0508</b>
	R <sup>2</sup>	0,8428	0,8443	<b>0,9994</b>
	RMSE	0,1091	0,1088	<b>0,0206</b>
Adım 5	MAPE	0,4028	0,3882	<b>0,0691</b>
	R <sup>2</sup>	0,8440	0,8438	<b>0,9995</b>
	RMSE	0,1089	0,1082	<b>0,0203</b>

Kış veri seti sonuçları Çizelge 6.13'te incelendiğinde, önerilen hibrit model, en düşük RMSE 0,0203 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir. En yüksek R<sup>2</sup> değerine bakıldığında 0,9998 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0,0125 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve R<sup>2</sup>) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Çizelge 6.14'te sonbahar veri seti ile diğer modeller karşılaştırılmıştır.

Çizelge 6.14. Sonbahar veri seti üzerinden hibrit modellerin karşılaştırılması

Tahmin	Metrikler	EEMD-EWT-BP	EEMD-VDM-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0,5097	0,4991	<b>0,058</b>
	R <sup>2</sup>	0,8084	0,8105	<b>0,9995</b>
	RMSE	0,1188	0,1177	<b>0,0189</b>
Adım 2	MAPE	0,5031	0,4905	<b>0,0113</b>
	R <sup>2</sup>	0,8133	0,8213	<b>0,9996</b>
	RMSE	0,1175	0,1148	<b>0,0319</b>
Adım 3	MAPE	0,5108	0,4927	<b>0,0885</b>
	R <sup>2</sup>	0,8041	0,8018	<b>0,9992</b>
	RMSE	0,1197	0,1195	<b>0,0243</b>
Adım 4	MAPE	0,5168	0,5314	<b>0,0114</b>
	R <sup>2</sup>	0,8007	0,7073	<b>0,9995</b>
	RMSE	0,1196	0,1288	<b>0,0335</b>
Adım 5	MAPE	0,5229	0,5043	<b>0,0174</b>
	R <sup>2</sup>	0,7901	0,7912	<b>0,9992</b>
	RMSE	0,1217	0,1226	<b>0,0458</b>

Sonbahar veri seti sonuçları Çizelge 6.14’de incelendiğinde, önerilen hibrit model, en düşük RMSE 0,0189 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir. En yüksek R<sup>2</sup> değerine bakıldığında 0,9996 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0,0113 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve R<sup>2</sup>) önerdiğimiz hibrit model en iyi sonuçları vermiştir. Çizelge 6.15’te yaz veri seti ile diğer modeller karşılaştırılmıştır.

Çizelge 6.15. Yaz veri seti üzerinden hibrit modellerin karşılaştırılması

Tahmin	Metrikler	EEMD-EWT-BP	EEMD-VDM-BP	CEEMDAN-LMD-HURST-BP (Hibrit Model)
Adım 1	MAPE	0,4326	0,5642	<b>0,1152</b>
	R <sup>2</sup>	0,8071	0,3869	<b>0,9998</b>
	RMSE	0,1536	0,1923	<b>0,0403</b>
Adım 2	MAPE	0,4571	0,6190	<b>0,0887</b>
	R <sup>2</sup>	0,7231	0,4142	<b>0,9992</b>
	RMSE	0,1589	0,2035	<b>0,0322</b>
Adım 3	MAPE	0,4678	0,7576	<b>0,0801</b>
	R <sup>2</sup>	0,7249	-0,3196	<b>0,9992</b>
	RMSE	0,1640	0,2470	<b>0,0319</b>
Adım 4	MAPE	0,4705	0,6879	<b>0,0952</b>
	R <sup>2</sup>	0,6768	0,0459	<b>0,9999</b>
	RMSE	0,1650	0,2295	<b>0,0377</b>
Adım 5	MAPE	0,4787	0,7906	<b>0,0539</b>
	R <sup>2</sup>	0,5604	-0,5799	<b>0,9995</b>
	RMSE	0,1722	0,2538	<b>0,0270</b>

Yaz veri seti sonuçları Çizelge 6.15'te incelendiğinde, önerilen hibrit model, en düşük RMSE 0,0270 değerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarının yüksek olduğunu göstermektedir. En yüksek R<sup>2</sup> değerine bakıldığında 0,9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0,0539 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür. Tüm tahmin modellerinin performans değerlendirmesinde (RMSE, MAPE ve R<sup>2</sup>) önerdiğimiz hibrit model en iyi sonuçları vermiştir.

## 7. SONUÇLAR

Son yıllarda artan enerji taleplerini karşılamak için gereken enerjiye güvenilir kaynaklardan, en ucuz ve en kaliteli yöntemlerle ulaşmak oldukça önemlidir. Çünkü günümüzde hala enerji ihtiyacının büyük bir bölümünün fosil kaynaklı yakıtlardan elde edilmesi ve bu yakıtların sınırlı rezervlere sahip olması çalışmaları yenilenebilir enerji kaynaklarına yönlendirmiştir. Çevresel açıdan sağladığı faydalara rağmen, rüzgar gücünün doğal belirsizliği, enerji sistemlerinin çalışmasında zorluklar doğurmaktadır. Enterkonnekte sistemde rüzgar gücünden elektrik üretim tahmini, sistem operatörleri açısından son derece önemlidir. Dolayısıyla doğru üretim planı yapılabilmesi, doğru rüzgar hızı/gücü tahminine bağlıdır. Bu sebeple çalışmalar doğru rüzgar hızı tahmininde yoğunlaşmaktadır. Bu çalışmada ikincil ayrıştırma tabanlı hibrit beş adımlı tahmin modelleri kullanılarak rüzgar hızı tahminlemesi gerçekleştirilmiştir.

Rüzgar hızı tahmini için yeni bir hibrit modelin önerildiği çalışmada, rüzgar hızı verileri 2017 – 2019 yılı boyunca 10’ar dakika aralıklarla kaydedilen, 2 farklı veri seti kullanılmıştır. Birincisi her ayın haftalarına karşılık gelen verilerin ortalaması olan 48 adet veriye sahip haftalık veri setidir. Diğeri ise aynı yıllık (Hangi yılların verileri olduğunu belirtelim) verinin ilkbahar (Şubat, Mart, Nisan), yaz (Mayıs, Haziran, Temmuz), sonbahar (Ağustos, Eylül, Ekim) ve kış (Kasım, Aralık, Ocak) şeklinde mevsimsel olarak düzenlenerek her bir mevsim için 12.096 adet verinin bulunduğu çalışma setidir. Üç farklı vaka çalışması yapılmıştır. Tüm vakalarda hurst üstel katsayısı ile macro, micro ve meso alt gruplar oluşturulmuş ve bunlar geri yayımlı yapay sinir ağında kullanılmıştır. Veri setleri, önerilen hibrit model dışında farklı tahmin modelleri ile karşılaştırılmıştır.

Birinci vaka çalışmasında, 48 adet haftalık ortalama veri seti, 5 farklı ayrıştırma tekniğinden (CEEMDAN–LMD–BP, LMD–BP, CEEMDAN–BP, BP, CEEMDAN–LMD–Hurst–BP) oluşan modellerle tahminlemesi yapıp sonuçlar karşılaştırılmıştır. Birinci vaka analiz sonuçlarında tüm modellerin 5 adımlı tahminlemesinde meso veri seti oluşmadığından tahminlemede kullanılmamıştır. Macro ve micro kendi içerisinde incelendiğinde en iyi sonucun micro veri setinde olduğu görülmektedir. Hurst analizinde

micro deęer anti – kalıcı özellięi olan verilerdir. Bu doęrusal ve duraęan olmayan rüzgar hızı verisi ile örtüşen bir durumdur. Sonuçta tahmin sonuçlarının deęerlendirilmesinde micro verilerin dikkate alınmasının tahmin doęruluęu üzerinde etkili olduęu söylenebilir. Dolayısıyla önerdięimiz modelin (CEEMDAN – LMD – HURST – BPNN) tahminleme üzerine dięer modellerden daha iyi sonuç verdięi görülmüştür. Haftalık veri seti üzerinden sonuçlar kapsamlı bir şekilde incelendięinde hibrit modelin tüm tahmin adımlarında, hesaplanan MAPE: 0.38,  $R^2$ : 0.80, RMSE: 0.15 deęerleri ile en iyi hata metrikleri verdięi görülmektedir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduęundan başarının yüksek olduęunu göstermektedir. En yüksek  $R^2$  deęerine bakıldıęında ise bire en yakın sonuç elde edilmiştir. En düşük MAPE deęeri ile hata deęeri ve yüksek doęruluk oranına sahip olduęu görülmüştür.

İkinci vaka çalışmasında mevsimsel verilerin analiz sonuçlarının 5 adımlı tahminlemede kış mevsim için yapılan analizlerde, en düşük RMSE 0.0203 deęerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduęundan başarının yüksek olduęunu göstermektedir. En yüksek  $R^2$  deęerine bakıldıęında 0.9995 deęeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0691 deęeri ile en düşük hata deęeri ve yüksek doęruluk oranına sahip olduęu görülmüştür. Yaz mevsimi analizlerinde önerilen hibrit model ile en düşük RMSE deęeri 0.0270 olarak hesaplanmıştır. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduęundan başarının yüksek olduęunu göstermektedir. En yüksek  $R^2$  deęerine bakıldıęında 0.9995 deęeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0539 deęeri ile en düşük hata deęeri ve yüksek doęruluk oranına sahip olduęu görülmüştür. Sonbahar mevsim verisinde önerilen hibrit model, en düşük RMSE 0.0189 deęerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduęundan başarının yüksek olduęunu göstermektedir. En yüksek  $R^2$  deęerine bakıldıęında 0.9995 deęeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0580 deęeri ile en düşük hata deęeri ve yüksek doęruluk oranına sahip olduęu görülmüştür. İlkbahar mevsim verisinde önerilen hibrit model, en düşük RMSE 0.0080 deęerini göstermiştir. RMSE sonucunun sıfıra yakın olması gerçek



veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir En yüksek  $R^2$  değerine bakıldığında 0.9999 değeri ile de bire en yakın sonuç elde edilmiştir. MAPE 0.0600 değeri ile en düşük hata değeri ve yüksek doğruluk oranına sahip olduğu görülmüştür.

Üçüncü vaka çalışmasında ise önerdiğimiz hibrit model literatürde yaygın olarak kullanılan EEMD-EWT ve EEMD-VMD hibrit modelleri kıyaslanmıştır. Tüm veri setleri kullanılarak gerçekleştirilen birden beş adımlı tahminlemede, önerilen hibrit modelin diğer hibrit modellerden daha iyi sonuçlara sahip olduğu görülmüştür.

Önerilen hibrit modelin haftalık, sonbahar, ilkbahar, yaz ve kış mevsim verileri üzerinde tüm adımlar içerisinde en iyi hata metrikleri Çizelge 7.1’de gösterilmiştir.

Çizelge 7.1. Verilerden elde edilen en iyi hata metrikleri

<b>Tahmin</b>	<b>İlkbahar</b>	<b>Yaz</b>	<b>Sonbahar</b>	<b>Kış</b>	<b>Haftalık</b>
<b>MAPE</b>	0,0005	0,0539	0,0113	0,0125	0,0123
<b>R<sup>2</sup></b>	0,9999	0,9998	0,9996	0,9998	0,9950
<b>RMSE</b>	0,0130	0,0270	0,0189	0,0203	0,0249

Çizelge 7.1 incelendiğinde tüm adımlar içerisinde MAPE,  $R^2$  ve RMSE hata metriklerinde ilkbahar mevsimi en iyi sonuca sahip olmuştur. RMSE sonucunun sıfıra yakın olması gerçek veri ve tahmin edilen veri arasındaki farkın düşük olmasının bir sonucu olduğundan başarımın yüksek olduğunu göstermektedir. En yüksek  $R^2$  değerine bakıldığında ise bire en yakın sonuç elde edilmiştir. En düşük MAPE değeri ile hata değeri ve yüksek doğruluk oranına sahip olduğu görülmektedir. Önerilen hibrit modelin sonbahar mevsim verilerinde en iyi sonuçları gösterdiği görülmektedir.

Bu tez çalışmasında rüzgar hızı parametresi kullanılarak rüzgar hızı tahminlemesi için hibrit bir tahminleme modeli geliştirilmiştir. İkincil ayrıştırma tabanlı modelde hurst analizinin sonuçlarda etkili olduğu ve gelecek çalışmalarda rahatlıkla kullanılabileceği gösterilmiştir. Yapılan çalışma ile veri setinin kullanımında haftalık ortalama verilerin mevsimsel veri setlerine göre tahminlemede daha düşük sonuç gösterdiği görülmüştür.

Buda veri setinin yüksek olmasının alıřmalarda daha az hata oranı ile karřılařılacađını gstermiřtir. Aynı zamanda bu tez alıřmasının bilimsel katkıları ve yeniliki ynleri řu şekilde zetlenebilir: (1) Kısa ve orta vadeli rzgar hızlarının yüksek dođruluk ve gvenilirlikte tahminlenmesi iin ilk kez Uyarlanabilir Grltyle Tamamlanan Topluluk Ampirik Mod Ayrıřtırma (CEEMDAN, Complete Ensemble Empirical Mode Decomposition Adaptive Noise) – Lokal Ortalama Ayrıřtırması (LMD, Local Mean Decompositon) – Hurst stel Katsayısı – Geri yayılımlı sinir ađı (BPNN, Back-Propagation Neural Networks) adlı yeni bir adaptif dinamik hibrit model nerildi. Makine đrenmesi ve optimizasyon algoritmasını tam olarak dikkate alan bu model ile bireysel ayrıřtırma mimarilerini geride bırakan ift ayrıřtırma mimarisine odaklanılmaktadır; (2) LMD zellikle CEEMDAN’ı geliřtirmek iin kullanılır. CEEMDAN kullanan isel mod fonksiyonları (IMF’s, Intrinsic Mode Functions) arasında IMF1 en dzensiz ve sistematik olmayan para olduđundan yüksek frekanslı IMF1’in ikincil ayrıřtırmasında tahmin dođruluđunu artırmak iin LMD kullanılmıřtır. (3) nerilen modelle BPNN’n tahmin dođruluđu ve kararlılıđı da artırıldı; (4) alıřmanın diđer yeniliki ve nemli noktası ise benzer karakteristikler sergileyen IMF’ler Hurst analizi kullanılarak oklu lek analizi (micro, meso ve macro lekli) ile gruplandırıldı. Bylece tek lekte yapılan arařtırmalara gre daha dođru tahminleme yapıldıđı gibi rzgarın rastgelelik davranıř zelliđi de ortaya konmuřtur.

## 8. KAYNAKLAR

- Abdoos, A. A., 2016. A new intelligent method based on combination of VMD and ELM for short term wind power forecasting. *Neurocomputing*, Volume 203, 111–120.
- Akmandor, İ.S., Akgün, N., Altuntaşoğlu, Z.T., Malkoç, Y. ve Ayaz, F., 2009. Kısa Süreli Rüzgâr Enerjisi Tahminleri ve Tahmin Sistemleri-Rüzgâr Enerjisi Tahminleri, Tahmin Sistemleri ve Değişkenliği, Dünya Enerji Konseyi-Türk Milli Komitesi.
- An, X., Jiang, D., Zhao, M. ve Liu, C., 2012. Short-term prediction of wind power using EMD and chaotic theory. *Communications Nonlinear Science and Numerical Simulation*, Vol. 17, 1036–1042.
- Anonim, 2012. TÜREB, Türkiye Rüzgar Enerjisi Birliği, Türkiye Rüzgar Enerjisi İstatistik Raporu, <http://www.tureb.com.tr/turebsayfa/duyurular/turkiye-ruzgar-enerjisi-istatistik-raporu-ocak-2019>
- Anonim, 2019a. BP, Statistical Review of World Energy 2019 | 68th edition British Petroleum (BP), London, UK
- Anonim, 2019b. Küresel Rüzgar Enerji Konseyi 2018 Raporu. Küresel Rüzgar Enerji Konseyi (GWEC), <https://gwec.net/global-wind-report-2018/> (18.08.2019).
- Anonim, 2019c. Enerji ve Tabii Kaynaklar Bakanlığı. <https://www.enerji.gov.tr/tr-TR/Sayfalar/Elektrik> (11.07.2019).
- Anonim, 2019d. Türkiye Jeotermal Enerji Potansiyeli ve Arama Çalışmaları. Maden Tetkik ve Arama Genel Müdürlüğü (MTA), <http://www.mta.gov.tr/v3.0/arastirmalar/jeotermal-enerji-arastirmalari>, (20.08.2019).
- Aoife, M. F., Leahy, P. G., Marvuglia A. ve McKeogh E. J., 2012. Current methods and advances in forecasting of wind power generation. *Renew Energy*, Volume 37(1), 1–8.
- Aslan, N. ve Yamak, T., 2006. Türkiye'nin Enerji Sorununun Alternatif Enerji Kaynakları açısından değerlendirilmesi. *Marmara Üniversitesi İ.I.B.F. Dergisi*, Cilt XXI (1), 53-76.
- Bajaj, V. ve Pachori, R.B., 2012. Classification of seizure and nonseizure EEG signals usingempirical mode decomposition. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 16 (6), 1135–1142.
- Bayraç, H. N., 2011. Küresel Rüzgar Enerjisi Politikaları ve Uygulamaları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt/Vol. XXX (1), 37-57.
- Bayraktar, K.G., 2016. Güneş Ülkemizin Enerji Geleceğidir. *Enerji ve Maden Dergisi*, Yıl: 5, Sayı: 13 (50).
- Bokde, N., Feijóo, A. ve Kulat, K., 2018. Analysis of differencing and decomposition preprocessing methodsfor wind speed prediction. *Applied Soft Computing*, Volume 71, 926-938.
- Candy, B., English, S. J. and Keogh, S. J., 2009. A Comparison of the impact of QuikScat and WindSat wind vector products on met office analyses and forecasts. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 47 (6), 1632-1640.
- Canpolat, Ş., 2013. Rüzgar Enerjisi Ve Isparta Şartlarında Prototip Bir Rüzgar Türbini Tasarımı. (Yüksek Lisans Tezi), Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta.

- Cantürk, S., 2018. Bir Rüzgar Çiftliğinden Yapay Sinir Ağlarıyla Kısa Süreli Elektrik Üretim Tahmini. (Yüksek Lisans Tezi), Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara
- Catalao, J., Matias, J. ve Osorio, G., 2015. Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information. *Renewable Energy*, Volume 75, 301-307.
- Catalao, J., Pousinho, H. ve Mendes, V., 2009. An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal, *Intelligent System Application to Power Systems (ISAP)*.
- Chang, G.W., Lu, H.J., Chang, Y.R. ve Lee, Y.D., 2017. An improved neural network-based approach for short-term wind speed and power forecast. *Renew Energy*, Volume 105, 301–311.
- Chang, T.P., Ko, H.H., Liu, F.J., Chen, P.H., Chang Y.Y. ve Liang, Y.H., 2012. Fractal dimension of wind speed time series. *Apply Energy*, Volume 93, 742–749.
- Chang, T., Tu, Y., Chen, C. ve Chang, Y., 2012. Estimation of monthly wind power outputs of WECS With limited record period using artificial neural networks. *Energy Conversion and Management*, Volume 59, 114-121.
- Chang, W., 2013. A literature review of wind forecasting methods, *Power and Energy Engineering*, Volume 2, 161-168.
- Chatfield, C., 2002. Confessions of a pragmatic statistician. *The Statistician*, Volume 51, 1–20.
- Chen, C., Lee, Y. T. ve Chang, Y. F., 2008. A relationship between Hurst exponents of slip and waiting time data of earthquakes. *Physica A.*, Volume 387 (18), 4643–4648.
- Cheng, J., Zhang, K. Ve Yang, Y., 2012. An order tracking technique for the gear fault diagnosis using local mean decomposition method. *Mechanism and Machine Theory*, Volume 55, 67–76.
- Chitsaz, H., Amjady, N. ve Zareipour, H., 2015. Wind power forecast using wavelet neural network trained by improved Clonal selection algorithm. *Energy Conversion and Management*, Volume 89, 588-598.
- Çalışkan, M., 2011. Türkiye Rüzgar Enerjisi Potansiyeli ve Mevcut Yatırımlar. Rüzgar Enerjisi ve Santralleri Semineri, Rahmi Koç Müzesi Konferans Salonu, İstanbul.
- Çayıroğlu, İ., 2018. Görüntü İşleme -9. Hafta, Yapay Sinir Ağları. Karabük Üniversitesi, Mühendislik Fakültesi, Ders notları, [http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu\\_Isleme\\_Ders\\_Notlari-9.Hafta.pdf](http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-9.Hafta.pdf), (21.09.2019).
- Çetin, N.S., 2001. Küçük güçlü bir rüzgar türbini tasarımı ve elektrik enerjisi eldesi, VI. Türk-Alman Sempozyumu, Ege Üniversitesi Güneş Enerjisi Enstitüsü, İzmir.
- Çetin, N.S., 2006. Şebeke bağlantısız PM generatörlü rüzgar türbinlerinin YSA ile sistem optimizasyonu. (Doktora Tezi), Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Dündar, C., Oğuz, K., Dokuyucu, K. ve Bacanlı, H., 2011. Kısa Süreli Rüzgar Enerjisi Tahmini, VI. Yeni ve Yenilenebilir Enerji Kaynakları Sempozyumu, 21-22 Ekim 2011, Hilton Otel, Kayseri.
- Emeksiz, C., 2014. Şekil Hafızalı Alaşımın Kullanarak Sonlu Elemanlar Yöntemi İle Değişken Devirli Rüzgar Türbini Modellemesi. (Doktora Tezi), Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.

- Filik, Ü.B. ve Filik, T., 2017. Kısa-Donem Rüzgar Hızının Tahmininde Otoregresif ve Yapay Sinir Ağları Tabanlı Yeni Bir Hibrit Yaklaşım. *Karaelmas Fen ve Müh. Dergisi*, 7(2), 419-427.
- Flandrin, P., Rilling, G. ve Goncalves, P., 2004. Empirical mode decomposition as a filterbank. *IEEE Signal Processing Letters*, Vol. 11 (2), 112 - 114.
- Gilles, J., 2013. Empirical Wavelet Transform. *IEEE Transactions on Signal Processing*, Vol. 61 (16), 3999–4010.
- Guo, Z.H., Jie, W., Lu, H.Y. ve Wang, J.Z., 2011. A case study on a hybrid wind speed forecasting method using BP neural network. *Knowl-Based Systems*, Vol. 24 (7), 1048–1056.
- Hassan, A.R. ve Bhuiyan, M.H.I., 2016. Computer-aided sleep staging using completeensemble empirical mode decomposition with adaptive noise and bootstrap aggregating. *Biomedical Signal Processing and Control*, Vol. 24, 1–10.
- Hassan, A.R. ve Haque, M.A., 2015. Epilepsy and seizure detection using statistical features in the complete ensemble empirical mode decomposition domain, *IEEE Region 10 Conference*, Macaristan.
- He, Q., Wang, J. ve Lu, H., 2018. A hybrid system for short-term wind speed forecasting. *Applied Energy*, Volume 226, 756-771.
- Hui-Liu, H.T., Liang, X. ve Li, Y., 2015. Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks. *Application Energy*, Vol. 157, 183–194.
- Hu, J., Wang, J. ve Ma, K., 2015. A hybrid technique for short-term wind speed prediction. *Energy*, Vol. 81 (1), 563–574.
- Hu, J., Wang, J. ve Zeng, G., 2013. A hybrid forecasting approach applied to wind speedtime series, *Renewable Energy*, Volume 60, 185–194.
- Huang, N., Shen, Z., Long, S., Wu, M., Shih, H., Zheng, Q., Yen, N., Tung, C. ve Liu, H.H., 1998. The empirical mode decomposition and theHilbert spectrum for nonlinear and non-stationary time series analysis. *Proc.R. Soc. Lond. Ser. A: Math. Phys. Eng. Sci.*, Volume 454, 903–995.
- Hurst, H. E. (1951). Long-term storage capacity of reservoirs. *Transactions of the American Society of Civil Engineers*, 116, 770-799.
- İlkiliç, C., 2012. Wind energy and assessment of wind energy potential in Turkey, *Renewable and Sustainable Energy Reviews*, Volç 16 (2), 1165-1173.
- Jiang, P., Liu, F. ve Song, Y., 2017. A hybrid forecasting model based on date-framework strategy and improved feature selection technology for short-term load forecasting. *Energy*, 119, 694–709.
- Jung, J. ve Broadwater, R., 2014. Current status and future advances for wind speed and wind power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777.
- Kabalıcı, E., (2014). Yapay Sinir Ağları. Ders Notları, <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>, (22.08.2019).
- Karagöl, E. T. ve Kavaz, İ., 2017. Dünyada ve Türkiye’de Yenilenebilir Enerji. *Analiz Dergisi*, Sayı: 197.
- Karık, F., Sözen, A. ve İzgeç, M. M., 2017. Rüzgâr gücü tahminlerinin önemi: Türkiye elektrik piyasasında bir uygulama. *Politeknik Dergisi*, 20(4), 851-861.
- Koç, E. ve Şenel, M. C., 2013. Dünyada ve Türkiye’de Enerji Durumu – Genel Değerlendirme. *Mühendis ve Makina*, cilt 54 (639), 532-544.

- Koç, E. ve Kaplan, E., 2008. Dünyada ve Türkiye’de Genel Enerji Durumu-II Türkiye Değerlendirmesi. *Termodinamik Dergisi*, 188, 106-118.
- Kolhe, M., Lin, T. C. ve Maunuksela, J., 2011. GA-ANN for Short-Term Wind Energy Prediction. *Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 1-6.
- Köse, B., Recebli, Z. ve Özkaymak, M., 2014. Stokastik Modellerle Rüzgar Hızı Tahmini; Karabük Örneği, ISITES2014, Karabük.
- Kurbatskii, V.G., Sidorov, D.N., Spiryaev, V.A. ve Tomin, N.V., 2011. On the neural network approach for forecasting of nonstationary time series on the basis of the Hilbert-Huang transform. *Automation and Remote Control*, Vol. 72 (7), 1405-1414.
- Li, G. ve Shi, J., 2010. On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, Volume 87(7), 2313–2320.
- Li, G. ve Shi, J., 2012. Applications of Bayesian methods in wind energy conversion systems. *Renewable Energy*, 43, 1–8.
- Liang, Z., Liang, L., Zhang, L., Wang, C., Yun, Z. ve Zhang, X., 2015. Analysis of multi-scale chaotic characteristics of wind power based on Hilbert–Huang transform and Hurst analysis. *Applied Energy*, Vol. 159, 51–61.
- Liu, D., Li, H., Ma, Z., 2010. One hour ahead prediction of wind speed based on data mining. 2nd International conference on advanced computer control, Chine.
- Liu, D., Niu, D., Wang, H. ve Fan L., 2014. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm. *Renewable Energy*, Volume 62, 592–597.
- Liu, H., Mi, X. ve Li, Y., 2018. Comparison of two new intelligent wind speed forecasting approaches based on wavelet packet decomposition, complete ensemble empirical mode decomposition with adaptive noise and artificial neural networks. *Energy Conversion and Management*, 155, 188–200.
- Liu, H.C., Tian, H, Li, Y., 2015. Four wind speed multi-step forecasting models using extreme learning machines and signal decomposing algorithms. *Energy Conversion and Management*, Volume 100, 16–22.
- Lydia, M., Suresh Kumar, S., Selvakumar A. I. ve Prem Kumar, G. E., 2016. Linear and non-linear autoregressive models for short-term wind speed forecasting. *Energy Conversion and Management*, 112, 115–124.
- Mandelbrot, B.B. ve Van Ness, J.W., 1968. Fractional Brownian motions, fractional noises and applications. *SIAM Review*, Volume 10(4), 422–437.
- Meng, A., Ge, J., Yin, H. ve Chen, S., 2016. Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm. *Energy Conversion and Management*, Volume 114, 75–88.
- Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J. ve Conzelmann, G., 2009. *Wind Power Forecasting: State-of-the-Art 2009*. Argonne National Laboratory Report, Illinois
- Negnevitsky, M. ve Potter, C., 2006. Innovative Short-Term Wind Generation Prediction Techniques, 2006 IEEE PES Power Systems Conference And Exposition.
- Naik, J., Sujit, D. PK. ve Dash, R. B., 2017. Short term wind power forecasting using hybrid variational mode decomposition and multi-kernel regularized pseudo inverse neural network. *Renewable Energy*, Volume 118, 180-212.

- Özdamar, A., 2001. Rüzgar enerjisi ve rüzgar türbinlerine genel bakış. Yenilenebilir enerji kaynakları sempozyumu kitapçığı, İzmir.
- Özpinar, M.A., 2007. Yenilenebilir Enerji Santrallerinde Yapay Sinir Ağları Yöntemiyle Enerji Üretiminin Modellenmesi Ve Planlanması. (Doktora Tezi), Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalı, İstanbul.
- Öztürk, K. ve Şahin, M. E., 2018. Yapay Sinir Ağları ve Yapay Zeka'ya Genel Bir Bakış. Takvim-i Vekayi, Cilt: 6 (2), 25-36.
- Patel, M.R., 2006. Wind and Solar Power Systems. CRC Press, Boca Raton, Second Edition, 448, London.
- Peng, X., Zheng, W., Zhang, D., Liu, Y., Lu, D. ve Lin, L., 2017. A novel probabilistic wind speed forecasting based on combination of the adaptive ensemble of on-line sequential ORELM (Outlier Robust Extreme Learning Machine) and TVMCF (time-varying mixture copula function). Energy Conversion and Management, Volume 138, 587–602.
- Potter C.W. ve Negnevitsky M., 2006. Very short-term wind forecasting for Tasmanian power generation. IEEE Transactions on Power Systems, Volume 21(2), 965-972.
- Qian, Z., Pei, Y., Zareipour, H. ve Chen, N., 2019. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications. Applied Energy, Volume 235, 939-953.
- Qu, Z., Mao, W., Zhang, K., Zhang, W. ve Li, Z., 2019. Multi-step wind speed forecasting based on a hybrid decomposition technique and an improved back-propagation neural network. Renewable Energy, Vol. 133, 919-929.
- Ramasamy, P., Chandel, S.S. ve Yadav, A.K., 2015. Wind speed prediction in the mountainous region of India using an artificial neural network model. Renewable Energy, Volume 80, 338–347.
- Ramesh, B.N., Arulmozhivarman P., 2013. Improving forecast accuracy of wind speed using wavelet transform and neural networks. Journal of Electrical Engineering and Technology, Vol. 8 (3), 559-563.
- Rehman, S. ve Siddiqi, A.H., 2009. Wavelet based hurst exponent and fractal dimensional analysis of Saudi climatic dynamics. Chaos, Soliton & Fractals, Volume 40(3), 1081–1090.
- Ren, Y., Suganthan, P.N., Srikanth, N., 2014. A novel empirical mode decomposition with support vector regression for wind speed forecasting. IEEE Transactions on Neural Networks and Learning System, Vol. 27 (8), 1793–1798.
- Ren, Y., Suganthan, P.N. ve Srikanth, N., 2015. Ensemble methods for wind and solar power forecasting—a state-of-the-art review. Renewable and Sustainable Energy Reviews, Volume 50, 82–91.
- Sfestos, A., 2000. A comparison of various forecasting techniques applied to mean hourly wind speed time series. Renewable Energy, Volume 21, 23–35.
- Smith, J.C., Ahlstrom, M.L., Zavadil, R.M., Sadjadpour, A. ve Philbrick R.C., 2009. The Role of Wind Forecasting in Utility System Operations. IEEE Power and Energy Society General Meeting, Volume 2009, 1-5.
- Smith, J.S., 2005. The local mean decomposition and its application to EEG perception data. J. Roy. Soc. Interface, 2(5), 443–454.


- Sun, N., Zhou, J., Chen, L., Jia, B., Tayyab, M. ve Peng, T., 2018. An adaptive dynamic short-term wind speed forecasting model using secondary decomposition and an improved regularized extreme learning machine. *Energy*, Volume 165, 939-957.
- Sun, W. ve Wang, Y., 2018. Short-term wind speed forecasting based on fast ensemble empirical mode decomposition, phase space reconstruction, sample entropy and improved back-propagation neural network. *Energy Conversion and Management*, Volume 157, 1–12.
- Soğukpınar, H. ve Bozkurt, İ., 2014. Türkiye, Avrupa ve dünyada rüzgar enerjisi kullanımı, potansiyeli ve 2013 sonrası hedefler. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 1(1), 23-30.
- Soman, S.S., Zareipour, H., Malik, O.P. ve Mandal, P., 2010. A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons. *North American Power Symposium (NAPS)*.
- Şahin, A.D., 2001. Türkiye Rüzgarlarının Alan-Zaman Modellemesi. (Doktora Tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Şenkal, S., 2014. Rüzgar Hızı Tahmin Yöntemleri - Örnek Bir Uygulama. (Yüksek Lisans Tezi), Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun.
- Taşçıkaraoğlu, A. ve Uzunoğlu, M., 2011. Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Rüzgar Hızı Tahmini. *Elektrik-Elektronik ve Bilgisayar Sempozyumu FEEB 2011*, Fırat Üniversitesi-Elazığ, 5-7 Ekim 2011.
- Taşçıkaraoğlu, A. ve Uzunoğlu, M., 2014. A review of combined approaches for prediction of short term wind speed and power. *Renewable and Sustainable Energy Reviews*, Volume 34(6), 243–254.
- Tian, C., Hao, Y. ve Hu, J., 2018. A novel wind speed forecasting system based on hybrid data preprocessing and multi-objective optimization. *Applied Energy*, Volume 231, 301-319.
- Torres, M., Colominas, M., Schlotthauer, G. ve Flandrin, P., 2011. A complete ensemble empirical mode decomposition with adaptive noise. *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 4144–4147, Prague, Czech Republic.
- Torun, E., 2012. Hht Analizine İlişkin Yeni Yaklaşımlar: Sermaye Piyasası Üzerine Bir Uygulama. (Doktora Tezi), Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, İzmir.
- Türkyılmaz, F., 1997. Saatlik ve Aylık Rüzgar Verisiyle Rüzgar Enerjisi Modellenmesi. (Doktora Tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Uygun, C. ve Eker, K., 2009. Rüzgar Enerji Santrallerinin Şebekeye Bağlanması Durumunda Enerji Kalitesi Üzerindeki Etkilerinin İncelenmesi, *Türkiye 11. Enerji Kongresi*, 21-23 Ekim İzmir.
- Wang, J., Shanshan, Q., Zhou, Q. Ve Jiang, H., 2015. Medium-term wind speeds forecasting utilizing hybrid models for three different sites in Xinjiang, China, *Renew. Energy*, 76, 91-101.
- Wang, S., Zhang, N., Wu, L. ve Wang, Y., 2016. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method. *Renewable Energy*, Volume 94, 629–636.
- Wei, S. ve Liu, M., 2016. Wind speed forecasting using FEEMD echo state networks with RELM in Hebei, China. *Energy Conversion Management*. Vol. 114, 197–208.
- Wu Y.K. ve Hong J.S., 2007. A literature review of wind forecasting technology in the World. *IEEE Lausanne PowerTech Proceedings*, Lausanne, Switzerland.



- Wu, Z. ve Huang, N.E., 2011. Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances Adaptive Data Analysis*, Vol. 1(1), 1–41.
- Xiao, L., Shao, W., Yu, M., Ma, J. ve Jin C., 2017. Research and application of a hybrid wavelet neural network model with the improved cuckoo search algorithm for electrical power system forecasting. *Applied Energy*, Vol. 198, 203–222.
- Yağcı, E., 2013. Rüzgar hızı yükseltmelerinde kullanılan farklı yöntemlerin karşılaştırılması ve hata analizleri. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Yanıktepe B., Savrun M. ve Koroglu T., 2013. Current status of wind energy and wind energy policy in Turkey, *Energy Conversion and Management*, 72, 103-110.
- Yeh, J-R., Sheih, J-S ve Huang N., 2011. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method. *Advances in Adaptive Data Analysis*, 2(2), 135-156.
- Yu, C., Li, Y. ve Zhang M., 2017. Comparative study on three new hybrid models using Elman neural network and empirical mode decomposition based technologies improved by singular spectrum analysis for hour-ahead windspeed forecasting, *Energy Convers. Manage*, Volume 147, 75–85.
- Zhang, L.L., Li, M.S., Ji, T.Y. ve Wu, Q.H., 2016. Short-term wind power prediction based on intrinsic time-scale decomposition and LS-SVM. 2016 IEEE Innovative Smart Grid Technologies - Asia (ISGT-Asia), Melbourne, Australia.
- Zhang, W., Qu, Z., Zhang, K., Mao, W., Ma, Y. ve Fan, X., 2017. A combined model based on CEEMDAN and modified flower pollination algorithm for wind speed forecasting. *Energy Conversion and Management*, Vol.136, 439–451.
- Zhang, W., Wang, J., Wang, J., Zhao, Z. ve Tian, M.. 2013. Short-term wind speed forecasting based on a hybrid model. *Applied Soft Computing*, Vol. 13(7), 3225–3233.
- Zhang, W.H. ve Li, X.G., 2009. Origin of pressure fluctuations in an internal-loop airlift reactor and its application in flow regime detection. *Chem. Eng. Sci.*, Vol. 64, 1009–1018.
- Zhou, Q., Jiang, H., Wang, J. ve Zhou, J., 2014. A hybrid model for PM2.5 forecasting based on ensemble empirical mode decomposition and a general regression neural network. *Science of The Total Environment*, 264-274.

## 9. EKLER

### EK-1. Önerilen hibrit model



## 10. ÖZGEÇMİŞ

### Kişisel Bilgiler:

Adı Soyadı : Mustafa TAN  
Telefonlar : 90 506 371 65 00  
E-mail : [mustafa.tan@turktelekom.com.tr](mailto:mustafa.tan@turktelekom.com.tr)  
Doğum tarihi ve yeri : 14.07.1979 / Duisburg - Almanya

### Deneyim:

#### **Ekip Lideri - Türk Telekom A.Ş. İl Müdürlüğü, Tokat**

Eylül 2007 - Şu Anda, Network Ekip Lideri

#### **Proje Yöneticisi - HB TEKNİK ELK DANIŞMANLIK TAAHHÜT LTŞ, İstanbul**

Şubat 2006 - Eylül 2007, Proje Yöneticisi

#### **Departman Sorumlusu - DOXINN Büro Makinaları LTŞ., Kayseri**

Mayıs 2004 - Kasım 2004, Teknik Servis Departmanı Sorumlusu

#### **Stajyer - Türk Telekom A.Ş. İl Müdürlüğü, Tokat**

Temmuz 2002, Bilgi işlem stajyeri

#### **Stajyer - KOÇBANK A.Ş. Genel Müdürlük, İstanbul**

Temmuz 2001, Bilgi işlem stajyeri

#### **Bilgisayar işletmeni - KIA Motor A.Ş. Genel Müdürlük, İstanbul**

Şubat 1997 - Mayıs 1998, Tekniker / Bilgisayar İşletmeni

### Eğitim:

#### **Gaziosmanpaşa Üniversitesi - Tokat**

Y.Lisans, Elektrik-Elektronik Mühendisliği, 2018 – 2020

#### **Gaziosmanpaşa Üniversitesi - Tokat**

Y.Lisans, Biyosistem Mühendisliği, 2011 – 2015

#### **Erciyes üniversitesi - Kayseri**

Lisans, Elektronik Mühendisliği, 1999 – 2005

#### **Marmara üniversitesi - İstanbul**

Ön lisans, Elektronik, 1996 – 1998

#### **19 Mayıs Lisesi - Samsun**

Lise, Matematik, 1993 – 1996

### Yabancı Dil

İngilizce [ Okuma:6 Yazma:4 Konuşma:5 ]

### Projeler:

#### **113 R 039 NOLU TÜBİTAK 1001 Bilimsel Ve Teknolojik Araştırma Projesi**

Nisan 2014 - Ekim 2017

Ekip Üyeleri: Prof.Doç.Dr. Sefa TARHAN, Yrd.Doc.Dr. Mehmet Metin ÖZGÜVEN,  
Dr. Adil Koray YILDIZ, Mustafa TAN

Proje Başlığı: Büyük Ölçekli Süt Sığırı İşletmelerinde Sığırların Sağlık Ve Kızgınlık Durumlarının Tespitine Yönelik Yeni Bir Otomasyon Sisteminin Geliştirilmesi

Projede **Yardımcı Araştırmacı** olarak görev aldım.

#### **Robot PARS Projesi 2**

17 - 19 Haziran 2015

Ekip Üyeler: Mustafa Tan, Cemil közkurt, Yrd.Doc.Dr. Mehmet Metin Özgüven,  
Mustafa Özsoy

Slovenya'nın Maribor Üniversitesi, Tarım ve Yaşam Bilimleri Fakültesi, Biyosistem Mühendisliği tarafından organize edilen Field Robot Event 2015 yarışmasına üniversitemiz adına katıldık. 1 yıl süren projenin donanım yazılımları ve malzeme seçimleri ile **Takım Lideri** görevlerini yaptım.

#### **Robot PARS Projesi**

16 - 18 Haziran 2014

Ekip Üyeleri: Mustafa Tan, Muhammed Mahbub İBİS, Onuralp SEZER, Yrd.Doc.Dr. Mehmet Metin Özgüven

Almanya'nın Bernburg-Strenzfeld kentinde düzenlenen Field Robot Event 2014 yarışmasına üniversitemiz adına katıldık. 6 ay süren projenin tüm süreçlerinin takibi (yazışmalar, sponsorluk anlaşmaları, takım üyelerinin seçimi ve görev dağılımı, ulaşım, konaklama, malzeme alımları gibi parasal konuların takibi vs.) tarafımda yapılmıştır. Ayrıca projede **Takım Lideri** olarak da görev yaptım.

#### **2014/85 Gaziosmanpaşa Üniversitesi BAP Projesi**

Eylül 2014 – Ekim 2015

Ekip Üyeler: Yrd.Doc.Dr. Mehmet Metin Özgüven, Mustafa Özsoy, Mustafa Tan, Cemil Közkurt, Muzaffer Hakan Yardım

Proje Başlığı: Çok Amaçlı Tarım Robotunun Geliştirilmesi

Projede donanım ve yazılım konularında görev aldım.

#### **2013/36 Gaziosmanpaşa Üniversitesi BAP Projesi**

Ocak 2013 – Eylül 2014

Ekip Üyeler: Yrd.Doc.Dr. Mehmet Metin Özgüven, Mustafa Tan

Proje Başlığı: Radyo Frekanslı (RF) Pedometrenin Geliştirilmesi ve Kalibrasyonu

Projede donanım ve yazılım konularında görev aldım.

#### **Lisans Dönemi Yapılan Projeler**

2002 Proje I : Otomatik kapı için PLC programlaması ve kontrolü

2003 Proje II : Yapay Sinir Ağları'nın Tıp'ta, Hastalık Tanı ve Teşhisinde Kullanımı

2004 Bitirme projesi : Morbid Obezite Hastaları İçin Takılabilir Gastrit Uyarıcı Cihazı Tasarımı (Türkiye'de lisans ve yüksek lisans düzeyindeki ilk çalışmadır).

#### **Sertifikalar:**

##### **T.H.K. Türkkuşu Paraşütçü Sertifikası**

Lisans 33016, Nisan 2000

##### **İngilizce sertifikası**

Erciyes üniversitesi Yabancı Diller Yüksek Okulu İngilizce sertifikası,  
Haziran 2000

##### **Girişimcilik sertifikası**

GUGİM tarafından düzenlenen "TÜBİTAK Destekli Girişimcilik Sertifika Programı" çerçevesinde alınmış, projem 3. olmuştur. Şubat 2016

#### **Yayımlar:**

##### **Tarımda Radyo Frekans (RF) İletişim Uygulamaları**

TARMEK2013, 6 Eylül 2013

Yazarlar: Mustafa TAN, Prof.Doç.Dr. Sefa TARHAN, Yrd.Doc.Dr. Mehmet Metin ÖZGÜVEN

### **Yürümenin Kilo Verme Üzerine Etkisinin Modellenmesi**

Elektrik Mühendisliği Dergisi Sayı:448, Ekim 2013

Yazar: Mustafa TAN

### **Drone Sistemlerin Hassas Tarımda Kullanımı**

TARMEK2015, 6 Eylül 2015

Yazarlar: Mustafa TAN, Prof.Doç.Dr. Sefa TARHAN, Yrd.Doc.Dr. Mehmet Metin ÖZGÜVEN

### **Çok Amaçlı Tarım Robotunun Geliştirilmesi**

TARMEK2016, 3 Eylül 2016

Yazarlar: Yrd.Doc.Dr. Mehmet Metin ÖZGÜVEN, Mustafa TAN, Cemil KÖZKURT, Muzaffer Hakan YARDIM, Mustafa ÖZSOY, Eray SABANCI

### **Design of Pedometer with Radio Frequency (RF)**

Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi (JAFAG), Sayı : 33 (3), Sayfa : 28-38. Kabul Tarihi : 14.11.2016

Yazarlar: Yrd.Doc.Dr. Mehmet Metin ÖZGÜVEN, Mustafa TAN

### **Kızgınlık Tespitinde Kullanılan Pedometrelerde Kablosuz Veri Gönderim Yöntemleri (Sözlü Bildiri)**

2. Ulusal Biyosistem Mühendisliği Kongresi, Tokat. 29 Haz. – 1 Tem. 2017

Yazarlar: Yrd.Doc.Dr. Mehmet Metin ÖZGÜVEN, Mustafa TAN

### **Gönüllü Deneyim:**

#### **Katılımcı ve refakatçı - Çanakkale Kültür Gezisi**

6 – 9 Ağustos 2015 (3 gün)

“Çanakkale Kültür Gezisi” değişik yaş gruplarından oluşturulan gezi grubu ile 2 gece / 3 gündüz İstanbul – Çanakkale – Bursa güzergâhı şeklinde, 6-9 Ağustos tarihleri arasında 45 kişilik grupla kültür gezisini tamamlanmıştır.

#### **4007 – TÜBİTAK Bilim Şenlikleri Destekleme Programı**

20 Mayıs 2016

TOKİ ilköğretim okulunda gerçekleştirilen bilim şenliğinde sergilenen ve çocukları eğlendiren “Çöp Canavarı” isimli robot yapımında öğrencilere destek oldum.