



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA PROGRAMI

**RÜZGAR HIZI TAHMİNLEMESİNDE İKİNCİL AYRIŞTIRMALI VE
DALGACIK SINIR AĞI TEMELLİ YENİ BİR HİBRİT YAKLAŞIM**

DOKTORA TEZİ

SERKAN ŞENKAL

Danışman: Doç. Dr. Cem EMEKSİZ

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Cem EMEKSİZ danışmanlığında hazırlamış olduğum “Rüzgar Hızı Tahminlemede İkincil Ayırıştırma ve Dalgacık Sınır Ağı Temelli Yeni Bir Hibrit Yaklaşım” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

27/05/2024

Serkan ŞENKAL



ÖZET

RÜZGAR HIZI TAHMİNLEMESİNDE İKİNCİL AYRIŞTIRMALI VE DALGACIK SİNİR AĞI TEMELLİ YENİ BİR HİBRİT YAKLAŞIM

Şenkal, Serkan

Doktora, Mekatronik Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Cem Emeksiz

Mayıs 2024, xix + 142 sayfa

Enerji tüketimi ile küreselleşme, kentleşme, enerji politikaları ve ekonomik büyüme gibi çeşitli faktörler arasındaki ilişkiyi içeren çalışmalarla literatürde sıklıkla karşılaşılmaktadır. Bu ilişki, sürdürülebilir enerji sistemlerine ulaşmak için politika ve stratejilerin önemini vurgular. Yenilenebilir enerji kaynakları çevresel faydalar sunar, karbon ayak izini azaltır ve enerji güvenliği ve bağımsızlığı sağlar. Ancak yenilenebilir enerjiye geçiş maliyetli olabilir ve jeopolitik riskler de tedarik zincirlerini ve dağıtımını etkileyebilir. Bu zorlukları aşmak için yenilenebilir enerji kaynaklarının çeşitlendirilmesi ve bölgesel iş birliği büyük önem taşır.

Yenilenebilir enerji, toplum ve çevre için birçok fayda sağlayan sürdürülebilir bir enerji kaynağıdır. İklim değişikliğine katkıda bulunan sera gazı emisyonlarını azaltır, halk sağlığını iyileştirir, su kirliliğini azaltır, ekosistemleri korur ve sürdürülebilir kaynak kullanımını teşvik eder. Ayrıca sürdürülebilir kalkınmayı destekler ve enerji sektöründe inovasyon ve araştırmaları ilerletir. Yenilenebilir enerji teknolojileri, tesis verimliliğini artırır ve düşük karbonlu teknolojilerde bir trend olarak öne çıkar.

Rüzgar enerjisinin anlaşılması ve kullanılmasında, rüzgar hızı önemli bir faktördür. Rüzgar türbinlerinin verimli çalışması, hava tahmini, iklim modellemesi ve açık deniz operasyonları için doğru rüzgar hızı tahmini önemlidir.

Rüzgar hızı tahmini için sinir ağları yaygın olarak kullanılır çünkü karmaşık doğrusal olmayan ilişkileri yakalama yetenekleri vardır. Birden fazla modelden elde edilen tahminleri birleştiren hibrit yaklaşımlar da umut vericidir. Değişken mod ayrıştırması (VMD) ve topluluk ampirik mod ayrıştırması (EEMD) gibi ayrıştırma tekniklerinin rüzgar hızı tahmininde önemli olduğu kanıtlanmıştır. Dalgacık sinir ağları (WNN'ler), aktivasyon işlevi olarak dalgacıkları kullanarak sinir ağlarının farklı giriş verisi özelliklerini yakalamasına ve performansını artırmasına olanak tanır. Rüzgar hızı tahmini için WNN'lere doğrudan referans olmamasına rağmen, mevcut çalışmalar rüzgar hızı tahmin doğruluğunu artırmak için farklı sinir ağı

mimarilerini dalgacık ayrıştırma teknikleriyle birleştirme potansiyelini göstermektedir. Çalışmamızda, çok kısa vadeli rüzgar hızı tahmininde başarıyı yüksek olacak şekilde, ikincil ayrıştırılmalı ve dalgacık sinir ağı ile oluşturulmuş bir hibrit model önerisinde bulunduk. Bu öneri doğrultusunda, popüler olarak kullanılan dört adet ayrıştırma modeli ile ikili olarak on altı adet ayrıştırma çifti ve üç tanesi yapay sinir ağı aktivasyon fonksiyonu, on üç tanesi dalgacık aktivasyon fonksiyonu olacak şekilde toplam on altı aktivasyon fonksiyonu ile 256 adet hibrit model oluşturulmuştur. Bu modeller ile dört mevsimin orta ayları için simülasyonlar yapılmış, ardından bu dört ayın sonuçları doğrultusunda başarıyı yüksek olan 48 model ile yılın diğer sekiz ayı simüle edilmiştir. Bulduğumuz sonuçlar, Ampirik Mod Ayrıştırması türevi olan CEEMDAN yöntemi ile Değişken Mod Ayrıştırma yönetimi (VMD) ile oluşturulan ikili ayrıştırma modelinin, SLOG2 dalgacık aktivasyon fonksiyonu sinir ağı ile oluşturulan hibrit tahmin modelinin yüksek başarımlı tahminler gerçekleştirdiği doğrultusundadır.

Anahtar Kelimeler: Rüzgar Hızı Tahmini, Veri Ayrıştırma, Yapay Sinir Ağı, Dalgacık Sinir Ağı

ABSTRACT

A NEW HYBRID APPROACH TO WIND SPEED FORECASTING BASED ON TWO-STAGE DECOMPOSITION AND WAVELET NEURAL NETWORK

Şenkal, Serkan

Doctorate Thesis, Division of Mechatronics Engineering

Advisor: Assoc. Prof. Dr. Cem Emeksiz

May 2024, xix + 142 pages

The literature is frequently encountered with studies on the relationship between energy consumption and various factors such as globalisation, urbanisation, energy policies and economic growth. This relationship emphasises the importance of policies and strategies for sustainable energy systems. Renewable energy sources offer environmental benefits, reduce carbon footprint and provide energy security and independence. However, the transition to renewable energy can be costly and geopolitical risks can also affect supply chains and distribution. Diversifying renewable energy sources and regional cooperation are crucial to overcome these challenges.

Renewable energy is a sustainable energy source with many benefits for society and the environment. It reduces greenhouse gas emissions contributing to climate change, improves public health, reduces water pollution, protects ecosystems, and promotes sustainable resource utilization. It also supports sustainable development and advances innovation and research in the energy sector. Renewable energy technologies improve plant efficiency and are a trend in low-carbon technologies.

Wind speed is an important factor in understanding and utilizing wind energy. Accurate wind speed prediction is important for the efficient operation of wind turbines, weather forecasting, climate modelling and offshore operations.

Neural networks are widely used for wind speed prediction because they can capture complex nonlinear relationships. Hybrid approaches that combine predictions from multiple models are also promising. Decomposition techniques such as variable mode decomposition (VMD) and ensemble empirical mode decomposition (EEMD) have proven to be important in wind speed prediction. Wavelet neural networks (WNNs) utilize wavelets as the activation function, allowing neural networks to capture different input data characteristics and improve performance. Although there is no direct reference to WNNs for wind speed prediction, existing

studies show the potential of combining different neural network architectures with wavelet decomposition techniques to improve wind speed prediction accuracy. Our study proposes a hybrid model with secondary decomposition and a wavelet neural network for very short-term wind speed forecasting. In line with this proposal, 256 hybrid models are created with sixteen decomposition pairs in pairs with four popularly used decomposition models and sixteen activation functions, three of which are neural network activation functions and thirteen of which are wavelet activation functions. With these models, simulations were viibritvir the middle months of the four seasons, and then the other eight months of the year were simulated with 48 models with high performance in line with the results of these four months. Our results viibr that the CEEMDAN method, which is a derivative of the Empirical Mode Decomposition, the binary decomposition model created with the Variable Mode Decomposition management (VMD), and the hybrid forecasting model created with the SLOG2 wavelet activation function neural network perform high-performance forecasts.

Keywords: Wind Speed Prediction, Data Decomposition, Artificial Neural Network, Wavelet Neural Network

TEŞEKKÜR

Bu tez çalışması, Değerli Danışmanım Sayın Doç. Dr. Cem EMEKSİZ'in titiz rehberliği ve değerli katkıları olmadan gerçekleşemezdi. Kendisinin bilgeliği, sabrı ve destekleri, bu çalışmanın her aşamasında beni aydınlatarak, yönlendirerek ve cesaretlendirerek yol almama yardımcı oldu.

Tez İzleme ve Tez Savunma Jürilerinde yer alan değerli hocalarıma da en içten teşekkürlerimi sunmak isterim. Değerli yorumları ve eleştirileri, bu çalışmanın kalitesini artırmak için önemli katkılar sağladı.

Ayrıca, sevgili eşim ve kızlarıma da tez sürecimde gösterdikleri sabır ve destek için minnettarım. Onların sabırlı ve anlayışlı tutumu, bu zorlu süreci daha da anlamlı ve güçlü kıldı.

Son olarak, tüm destekleriyle beni cesaretlendiren aileme ve sevdiklerime teşekkür ederim. Onların sevgisi ve desteği, her zaman benim için en büyük motivasyon kaynağı oldu ve olmaya devam edecektir.

İÇİNDEKİLER TABLOSU

ÖZET.....	iii
ABSTRACT.....	v
TEŞEKKÜR.....	vii
ŞEKİLLER LİSTESİ.....	xi
TABLOLAR LİSTESİ.....	xiv
KISALTMALAR VE SİMGELER LİSTESİ	xv
1. GİRİŞ	1
2. KURAMSAL TEMELLER	15
2.1. Rüzgar Hızı ve Rüzgar Gücü Arasındaki İlişki	15
2.2. Rüzgar Hızı Tahmininde Doğruluğun Önemi	16
2.3. Rüzgar Hızı Tahmininde Kullanılan Yöntemler	17
2.3.1. Sayısal Hava Tahmini	17
2.3.2. İstatistiksel Yöntemler.....	22
2.3.3. Makine Öğrenimi	24
2.3.4. Topluluk Yöntemleri.....	31
2.3.5. Hibrit Yaklaşımlar.....	33
2.4. Veri Ayırıştırması	34
2.5. Dalgacık sinir ağları.....	37
3. MATERYAL VE YÖNTEM.....	40
3.1. Atmosferik verilerin sağlanması.....	40
3.2. Veri Ayırıştırma Yöntemleri.....	41
3.2.1. Ampirik Mod Ayırıştırma (EMD, Empirical Mode Decomposition)	42
3.2.2. Topluluk Ampirik Mod Ayırıştırma (EEMD, Ensemble Empirical Mode Decomposition Method)	44
3.2.3. Tamamlayıcı Topluluk Ampirik Mod Ayırıştırma (CEEMD, Complementary Ensemble Empirical Mode Decomposition).....	47
3.2.4. Uyarlanabilir Gürültülü Tam Topluluk Ampirik Mod Ayırıştırması (CEEMDAN, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise)	48
3.2.5. Yerel Ortalama Ayırıştırması (LMD, Local Mean Decompositon)	50
3.2.6. Varyasyonel Mod Ayırıştırma (VMD, Variational Mode Decomposition)	50
3.3. Yapay Sinir Ağları.....	51
3.3.1. İleri Beslemeli Sinir Ağları (FNN, Feedforward Neural Networks):.....	56
3.3.2. Yinelemeli Sinir Ağları (RNN, Recurrent Neural Networks):.....	58

3.3.3.	Derin Öğrenme Modelleri:	60
3.3.4.	Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN):	61
3.3.5.	Tekrarlayan Evrişimli Sinir Ağları (Recurrent Convolutional Neural Networks - RCNN):	62
3.3.6.	Jeneratif Modeller:	64
3.4.	Dalgacık Sinir Ağları (WNN, Wavelet Neural Networks).....	68
3.4.1.	Tek boyutlu dalgacık sinir ağı.....	71
3.4.2.	Çok boyutlu dalgacık sinir ağı	73
3.5.	Hibrit Model İşlem Adımları.....	75
3.5.1.	Normalizasyon	77
3.5.2.	Sinir Ağı Mimarisinin Belirlenmesi.....	79
3.5.3.	Sinir Ağlarının Eğitilmesi	80
3.5.4.	YSA Aktivasyon Fonksiyonları	81
3.5.5.	DSA Aktivasyon Fonksiyonları	82
3.5.6.	Hibrit Modellerin Başarımı	83
4.	BULGULAR VE TARTIŞMA.....	84
4.1.	Bulgular	84
4.2.	Tartışma.....	98
5.	SONUÇLAR.....	100
6.	KAYNAKLAR	101
7.	EKLER.....	119
	EK 1: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve CEEMDAN+VMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları.....	119
	EK 2: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve EEMD+VMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları	123
	EK 3: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve LMD+EEMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları	127
	EK 4: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve LMD+LMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları	131
	EK 5: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve LMD+VMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları	135

EK 6: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve VMD+CEEMDAN+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları.....	139
--	-----



ŞEKİLLER LİSTESİ

Şekil No	Sayfa
Şekil 3.1. Ölçüm Direği.....	40
Şekil 3.2. Güç Kutusu.....	41
Şekil 3.3. Nöron (sinir hücresi) yapısı.....	53
Şekil 3.4. Nöronda eşik değeri gösterimi (Poznyak et al., 2001)	54
Şekil 3.5. Akson üzerinde bilgi iletimi	55
Şekil 3.6. İleri Beslemeli Sinir Ağı Mimarisi.....	58
Şekil 3.7. Yinelemeli Sinir Ağı Yapısı	59
Şekil 3.8. CNN Mimarisi ve Katmanlar	62
Şekil 3.9. Tekrarlayan Evrişimli Sinir Ağı Mimarisi.....	64
Şekil 3.10. Üretken Çekişmeli Ağların çalışma prensibi.....	65
Şekil 3.11. Varyasyonel Otomatik Kodlayıcılar.....	67
Şekil 3.12. Dalgacık sinir ağı yapısı	70
Şekil 3.13. Dalgacık nöronu.	71
Şekil 3.14. Dalgacık sinir ağı.....	72
Şekil 3.15. Çok boyutlu dalgacık aktivasyon fonksiyonlu dalgacık nöronu.....	74
Şekil 3.16. Hibrit Model Algoritması	75
Şekil 3.17. Sinir ağı eğitim ve tahmin süreci.....	76
Şekil 3.18. (a) Log-Sigmoid Transfer Fonksiyonu (b) Tan-Sigmoid Transfer Fonksiyonu (c) Purelin Transfer Fonksiyonu.....	81
Şekil 7.1. 1 Ocak 2020 tarihine ait basınç verisinin CEEMDAN + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri	119
Şekil 7.2. 1 Ocak 2020 tarihine ait sıcaklık verisinin CEEMDAN + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri	119
Şekil 7.3. 1 Ocak 2020 tarihine ait nem verisinin CEEMDAN + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri	120
Şekil 7.4. 1 Ocak 2020 tarihine ait basınç verisinin CEEMDAN + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	120
Şekil 7.5. 1 Ocak 2020 tarihine ait sıcaklık verisinin CEEMDAN + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	121
Şekil 7.6. 1 Ocak 2020 tarihine ait nem verisinin CEEMDAN + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	121
Şekil 7.7. 1 Ocak 2020 tarihine ait CEEMDAN + VMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini	122
Şekil 7.8. 1 Ocak 2020 tarihine ait basınç verisinin EEMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri	123
Şekil 7.9. 1 Ocak 2020 tarihine ait sıcaklık verisinin EEMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri	123
Şekil 7.10. 1 Ocak 2020 tarihine ait nem verisinin EEMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri	124
Şekil 7.11. 1 Ocak 2020 tarihine ait basınç verisinin EEMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	124
Şekil 7.12. 1 Ocak 2020 tarihine ait sıcaklık verisinin EEMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	125
Şekil 7.13. 1 Ocak 2020 tarihine ait nem verisinin EEMD + VMD ayrıştırma modeline ikincil göre ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	125
Şekil 7.14. 1 Ocak 2020 tarihine ait EEMD + VMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini	126

Şekil 7.15. 1 Ocak 2020 tarihine ait basınç verisinin LMD + EEMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	127
Şekil 7.16. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + EEMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	127
Şekil 7.17. 1 Ocak 2020 tarihine ait nem verisinin LMD + EEMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	128
Şekil 7.18. 1 Ocak 2020 tarihine ait basınç verisinin LMD + EEMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	128
Şekil 7.19. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + EEMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	129
Şekil 7.20. 1 Ocak 2020 tarihine ait nem verisinin LMD + EEMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	129
Şekil 7.21. 1 Ocak 2020 tarihine ait LMD + EEMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini	130
Şekil 7.22. 1 Ocak 2020 tarihine ait basınç verisinin LMD + LMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	131
Şekil 7.23. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + LMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	131
Şekil 7.24. 1 Ocak 2020 tarihine ait nem verisinin LMD + LMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	132
Şekil 7.25. 1 Ocak 2020 tarihine ait basınç verisinin LMD + LMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	132
Şekil 7.26. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + LMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	133
Şekil 7.27. 1 Ocak 2020 tarihine ait nem verisinin LMD + LMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	133
Şekil 7.28. 1 Ocak 2020 tarihine ait LMD + LMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini	134
Şekil 7.29. 1 Ocak 2020 tarihine ait basınç verisinin LMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	135
Şekil 7.30. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	135
Şekil 7.31. 1 Ocak 2020 tarihine ait nem verisinin LMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	136
Şekil 7.32. 1 Ocak 2020 tarihine ait basınç verisinin LMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	136
Şekil 7.33. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	137
Şekil 7.34. 1 Ocak 2020 tarihine ait nem verisinin LMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri	137
Şekil 7.35. 1 Ocak 2020 tarihine ait LMD + VMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini	138
Şekil 7.36. 1 Ocak 2020 tarihine ait basınç verisinin VMD + CEEMDAN ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	139
Şekil 7.37. 1 Ocak 2020 tarihine ait sıcaklık verisinin VMD + CEEMDAN ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	139
Şekil 7.38. 1 Ocak 2020 tarihine ait nem verisinin VMD + CEEMDAN ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri	140
Şekil 7.39. 1 Ocak 2020 tarihine ait basınç verisinin VMD + CEEMDAN ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri.....	140
Şekil 7.40. 1 Ocak 2020 tarihine ait sıcaklık verisinin VMD + CEEMDAN ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri.....	141

Şekil 7.41. 1 Ocak 2020 tarihine ait nem verisinin VMD + CEEMDAN ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri.....	141
Şekil 7.42. 1 Ocak 2020 tarihine ait VMD + CEEMDAN + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini	142



TABLolar LİSTESİ

Tablo No	Sayfa
Tablo 3.1. EMD ve geliştirilmiş versiyonlarının karşılaştırılması. (Qian ve ark., 2019)	49
Tablo 3.2. Veri ayrıştırma model listesi	77
Tablo 3.3. Dalgacık Aktivasyon Fonksiyonları	82
Tablo 4.1. Ocak ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	85
Tablo 4.2. Ocak ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri	86
Tablo 4.3. Nisan ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	87
Tablo 4.4. Nisan ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri	88
Tablo 4.5. Temmuz ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	89
Tablo 4.6. Temmuz ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri	90
Tablo 4.7. Ekim ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	91
Tablo 4.8. Ekim ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri	92
Tablo 4.9. En iyi 8 model sıralamasında bulunma yüzdesi	93
Tablo 4.10. 1 Ocak 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	94
Tablo 4.11. 1 Şubat 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	94
Tablo 4.12. 1 Mart 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	94
Tablo 4.13. 1 Nisan 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	95
Tablo 4.14. 1 Mayıs 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	95
Tablo 4.15. 1 Haziran 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	95
Tablo 4.16. 1 Temmuz 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	96
Tablo 4.17. 1 Ağustos 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	96
Tablo 4.18. 1 Eylül 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	96
Tablo 4.19. 1 Ekim 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	97
Tablo 4.20. 1 Kasım 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	97
Tablo 4.21. 1 Aralık 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri	97
Tablo 4.22. Mevsim ortası ayların YSA aktivasyon fonksiyonları + ikili ayrıştırma teknikleri yapılarında Ortalama Karesel Hata (MSE) çizelgesi	98

KISALTMALAR VE SİMGELER LİSTESİ

Simgeler	Açıklama
Ψ	Nöron çıkış fonksiyonu
ε	Hata terimi
N_b	Katman sayısı
N_{ϕ}	Çıktı katmanındaki nöron sayısını
N_d	Gözlem sayısını
N_g	Girdi katmanındaki nöron sayısını
N_s	Gizli katmandaki nöron sayısını
t	Genişleme parametresi
x'	Normalize edilmiş veriyi,
x_i	Girdi değerini,
$x_{\max}$	Girdi seti içerisinde yer alan en büyük sayı
$x_{\min}$	Girdi seti içerisinde yer alan en küçük sayı
λ	Öteleme parametresi
ϕ	Ölçekleme fonksiyonu

Kısaltmalar	Açıklama
1D-CNN	One-Dimensional Convolutional Neural Network, Tek Boyutlu Evrişimsel Sinir Ağı
AR	Auto-Regressive, Otoregresif
ARCH	Autoregressive Conditional Heteroscedasticity, Otoregresif Koşullu Değişen Varyans
ARDL	Autoregressive Distributed Lag Bound Test, Otoregresif Dağıtılmış

	Gecikme
ARFIMA	Autoregressive Fractionally Integrated Moving Averages, Oto regresif Kesirli Entegre Hareketli Ortalamaları
ARIMA	Autoregressive Integrated Moving Averages, Oto regresif Entegre Hareketli Ortalamalar
ARMA	Auto Regressive Moving Average, Oto regresif Hareketli Ortalama
Bi-LSTM	Bidirectional Long Short Term Memory, Çift Yönlü Uzun Kısa Süreli Bellek
BPN	Backpropagation Neural Network, Geri Yayılımlı Sinir Ağı
Catboost	Karar Ağaçları Üzerinde Gradyan Artırmaya Dayalı Bir Makine Öğrenimi Yöntemi
CEEMD	Complementary Ensemble Empirical Mode Decomposition, Tamamlayıcı Topluluk Ampirik Mod Ayrıştırma
CEEMDAN	Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, Uyarlanabilir Gürültülü Tam Topluluk Ampirik Mod Ayrıştırması
CFD	Computational Fluid Dynamics, Hesaplama Akışkanlar Dinamiği
CNN	Convolutional Neural Networks, Evrişimli Sinir Ağları
DCGAN	Deep Convolutional Generative Adversarial Network, Derin Evrişimli Üretken Karşıt Ağlar
DJIA	Dow Jones Industrial Average, Dow Jones Borsası Endüstri Endeksi
DNN	Deep Neural Network, Derin Sinir Ağı
DSA	Dalgacık Sinir Ağları, Wavelet Neural Network
DVAE	Descriptive Variational Autoencoder, Tamamlayıcı Varyasyonel Otomatik Kodlayıcının
DWT	Discrete Wavelet Transform, Ayrık Dalgacık Dönüşümü

DYY	Doğrudan Yabancı Yatırım
EEMD	Ensemble Empirical Mode Decomposition, Topluluk Ampirik Mod Ayırıştırması
EKF	Extended Kalman Filter, Genişletilmiş Kalman Filtresi
ELM	Extreme Learning Machine, Aşırı Öğrenme Makinesi
EMD	Empirical Mode Decomposition, Ampirik Mod Ayırıştırma
EMOS	Ensemble Model Output Statistic, Topluluk Model Çıktı İstatistikleri
EWS	Effective Wind Speed, Etkili Rüzgar Hızı
FA	Fuzzy ARTMA
FNN	Feedforward Neural Network, İleri Beslemeli Sinir Ağı
GA	Genetic Algorithm, Genetik Algoritma
GAN	Generative Adversarial Network, Üretken Karşıt Ağlar
GARCH	Generalized AutoRegressive Conditional Heteroskedasticity, Genelleştirilmiş Oto Regresif Koşullu Değişen Varyans
GMDH	Group Method Of Data Handling, Veri İşleme Grup Yöntemi
GP	Gaussian Process, Gauss Süreci
GRU	Gated Recurrent Units, Kapı Özyinelemeli Geçitler
GSA	Gravitational Search Algorithm, Yerçekimsel Arama Algoritması
GSYH	Gayrisafi Yurt İçi Hasıla
ICA	Independent Component Analysis, Bağımsız Bileşen Analizi
ICEEMDAN	Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, Uyarlanabilir Gürültü ile Geliştirilmiş Tam Topluluk Ampirik Mod Ayırıştırma
ILSVRC	ImageNet Large Scale Visual Recognition Challenge, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması

IMF	Intrinsic Mode Functions, İçsel Mod Fonksiyonları
ISCC	Iterative Cumulative Sum of Squares, İteratif Kümülatif Kareler Toplamı
LIDAR	Laser Imaging Detection and Ranging, Işık Tespiti ve Uzaklık Tayini
LM	Lagrange Multiplier, Lagrange Çarpanı
LMD	Local Mean Decomposition, Yerel Ortalama Ayırıştırması
LOGSIG	Log-sigmoid transfer fonksiyonu
LSSVM	Least Square Support Vector Machine, En Küçük Kareler Destek Vektör Makinesi
LSTM	Long Short-Term Memory, Uzun Kısa Süreli Bellek
Madaline	Multilayer Adaptive Linear Neuron, Çok Katmanlı Uyarlanabilir Doğrusal Nöron
MKL	Multiple Kernel Learning, Çoklu Çekirdek Öğrenme
MLP	Multi-Layer Perceptron, Çok Katmanlı Bir Algılayıcıyı
MRI	Magnetic Resonance Imaging, Manyetik rezonans görüntüleme
MSS	Merkezi Sinir Sistemi
NWP	Numerical Weather Prediction, Sayısal Hava Tahmini
PBL	Planetary Boundary Layer, Gezegenel Sınır Tabaka
PCA	Principal Component Analysis, Temel bileşen analizi
PGNN	Physics-induced Graph Neural Network, Fizik Güdümlü Sinir Ağı
PNN	Probabilistic Neural Network, Olasılıksal Sinir Ağı
PSO	Parçacık Sürüşü Optimizasyonu
PSS	Periferik Sinir Sistemi
PWS	Personal Weather Stations, Kişisel Meteoroloji İstasyonları
RBF	Radial Basis Function, Radyal Tabanlı Fonksiyon

RBFN	Radial Basis Function Network, Radyal Taban Fonksiyonu Ağı
REHS	Renewable Energy Hybrid System, Yenilenebilir Enerji Hibrit Sistemlerinin
SAE	Stacked Auto-Encoder, Yığılmış Otomatik Kodlayıcı
SDAE	Stacked Denoising Auto-Encoder, Yığılmış Gürültü Azaltıcı Otomatik Kodlayıcı
SVR	Support Vector Regression, Destek Vektör Regresyonu
TANSIG	Hiperbolik tanjant transfer fonksiyonu
Tobit	Değişken Varyanslı Sensör Regresyonu
UKF	Unscented Kalman Filter, Uyarlanmamış Kalman Filtresi
VAE	Variational Autoencoders, Varyasyonel Otomatik Kodlayıcılar
VMD	Variational Mode Decomposition, Varyasyonel Mod Ayırıştırması
WNN	Wavelet Neural Network, Dalgacık Sinir Ağları
WRF	Weather Research and Forecasting, Hava Araştırma ve Tahmin Modeli
WT	Wavelet Transform, Dalgacık Dönüşümü
YSA	Yapay sinir ağları

1. GİRİŞ

Enerji tüketimi, küresel kalkınma ve sürdürülebilirliğin önemli bir unsurudur. Birçok çalışma enerji tüketimi ile küreselleşme, kentleşme, enerji politikaları ve ekonomik büyüme gibi çeşitli faktörler arasındaki ilişkiyi araştırmıştır.

Shahbaz ve ark. (2021) tarafından yapılan bir çalışma, küreselleşme ile enerji tüketimi arasındaki nedensel ilişkiyi en üst ve en alt küreselleşmiş ekonomilerde araştırmıştır. Zamanla değişen Granger nedensellik testlerini kullanan çalışma, küreselleşme ve enerji tüketimi arasındaki dinamik nedensellik ilişkisinin zamanla değiştiğini bulmuştur. Küreselleşmedeki pozitif ve negatif şoklar enerji tüketimini pozitif ve negatif olarak etkilemektedir. Bu çalışma, küreselleşmenin enerji tüketimindeki teşvik edici rolünü vurgulamaktadır.

Zhao ve Qamruzzaman (2022) tarafından yapılan bir başka çalışma, Kuşak ve Yol ülkelerindeki enerji tüketiminde kentleşme, işçi dövizleri ve küreselleşmenin rolünü incelemiştir. Çalışma, küreselleşme ile enerji tüketimi arasında negatif ve istatistiksel olarak anlamlı bir ilişki bulmuştur. Küreselleşmenin enerji tüketimi üzerinde heterojen etkileri olduğunu ve siyasi, ekonomik ve sosyal küreselleşmenin enerji tüketimini farklı şekillerde etkilediğini öne sürmektedir.

Chen ve ark. (2022), Asya-Pasifik'teki gelişmekte olan ekonomilerin enerji dönüşümünde enerji politikalarının heterojen rolüne odaklanmıştır. Çalışma, yasa, düzenleme ve strateji politikalarının enerji geçişi üzerindeki olumlu etkilerini vurgulamaktadır. Stratejiler, enerji dönüşümünü kolaylaştırmada yasa ve yönetmeliklerden nispeten daha önemlidir. Çalışma, sürdürülebilir enerji sistemlerine ulaşmak için iyi tasarlanmış enerji politikalarının, hedeflenen stratejilerin ve düzenlemelerin önemini vurgulamaktadır.

Lawrence ve ark. (2013), 1980'den 2010'a kadar enerji tüketimindeki küresel eşitsizliği incelemiştir. Çalışma, kişi başına enerji tüketimindeki küresel eşitsizliği karakterize etmekte ve enerji tüketimi için üstel bir olasılık dağılımı önermektedir. Çalışma, enerji tüketiminde zengin ve fakir ülkeler arasındaki küresel eşitsizliği vurgulamaktadır.

Martinho (2018), küresel enerji üretimi ve tüketimini yakınsama teorisi perspektifinden analiz etmiştir. Çalışma, mutlak ve koşullu yakınsamanın neoklasik ve içsel büyüme teorilerini araştırmakta ve küresel enerji arzı ve talebiyle ilişkili değişkenlerde sigma yakınsamasına dair kanıtlar bulmuştur. Çalışma, yenilenebilir enerji kaynaklarını teşvik etmek için farklı karar alma düzeylerinde özelleştirilmiş politikalar önermektedir.

Koengkan (2017), Latin Amerika ve Karayip ülkelerinde küreselleşmenin birincil enerji tüketimi üzerindeki etkisini araştırmıştır. Çalışma, küreselleşme ile birincil enerji tüketimi arasındaki pozitif ilişkiyi doğrulamakta ve bunu toplam faktör verimliliğinin ve ekonomik büyümenin artmasına bağlamaktadır. Ekonomik büyümenin enerji talebini artırmadaki rolünü vurgulamaktadır.

Meng ve ark. (2020), tedarik zinciri boyunca küresel enerji tüketimine yapılan eşitsiz katkıyı tartışmıştır. Çalışma, tüketime dayalı enerji tüketimine en büyük katkıyı yapan sektör olarak hizmet sektörünün rolünü vurgulamıştır. Ayrıca, enerji tüketiminin hesaplanmasında enerji tüketimi ve uluslararası ticaretin etkileşiminin dikkate alınmasının önemini vurgulamıştır.

Yavuz ve ark. (2022) küreselleşmenin, yükselen ve büyümede öncü ekonomilerde enerji tüketimi üzerindeki etkilerini incelemiştir. Çalışma, küreselleşmenin enerji tüketimini artırdığını bulmakta ve ekonomik büyüme, kentleşme ve kamu harcamalarındaki değişikliklerin enerji tüketimi üzerindeki etkilerini tanımlamaktadır.

Shahbaz ve ark. (2017) gelişmiş ekonomilerde küreselleşme, ekonomik büyüme ve enerji tüketimi arasındaki nedensel ilişkiyi araştırmıştır. Çalışma, küreselleşmenin çoğu ülkede enerji tüketimini artırdığını ortaya koymakta ve sürdürülebilir ekonomik kalkınma için enerjinin verimli bir şekilde kullanılmasına yönelik politika yönergeleri sunmaktadır.

Lang ve Gregory (2019), küresel ısınmanın neden olduğu enerji tüketimindeki değişimin ekonomik etkilerini analiz etmiştir. Çalışma, küresel ısınmayı azaltmaya yönelik politikaların küresel ekonomiye zarar verebileceğini öne sürmektedir. Ampirik verilere dayanarak enerji etki fonksiyonlarının değiştirilmesi ve yeniden kalibre edilmesi gerektiğini vurgulamaktadır.

Bu alıřmalar gstermektedir ki enerji tknetimi ile kreselleřme, kentleřme, enerji politikaları ve ekonomik byme gibi eřitli faktrler arasındaki iliřkiye dair i gr saėlamaktadır. Bu iliřkinin karmařık ve heterojen yapısının altını izmekte ve srdrlebilir enerji sistemlerine ulařmak iin iyi tasarlanmıř politika ve stratejilerin nemini vurgulamaktadır.

Enerji kaynakları kkenlerine ve zelliklerine gre sınıflandırılır. Enerji kaynaklarının sınıflandırılması tipik olarak yenilenebilir ve yenilenemeyen kaynakları ierir.

Yenilenebilir enerji kaynakları doėal olarak yenilenen ve evre zerinde en az etkiye sahip olan kaynaklardır. Bu kaynaklar arasında gneř enerjisi, rzgar enerjisi, hidroelektrik enerji, biyoktle ve jeotermal enerji yer almaktadır. Gneř enerjisi, fotovoltatik hcreler veya solar termal sistemler gibi teknolojiler aracılıėıyla gneř iřıėının kullanılabilir enerjiye dnřtrlmesini ifade eder. Rzgar enerjisi, rzgar trbınlerini kullanarak elektrik retmek iin rzgarın gcnden yararlanır. Hidroelektrik enerji, elektrik retmek iin akan veya dřen suyun enerjisini kullanır. Biyoktle enerjisi bitkiler, tarımsal atıklar ve odun gibi organik maddelerden elde edilir. Jeotermal enerji, elektrik retmek veya ısıtma ve soėutma saėlamak iin Dnya'nın ekirdeėinden gelen ısıyı kullanır.

te yandan, yenilenemeyen enerji kaynakları sınırlıdır ve insan mr iinde yenilenemez. Bu kaynaklar kmr, petrol ve doėal gaz gibi fosil yakıtları ierir. Fosil yakıtlar, milyonlarca yıl boyunca jeolojik srelerden geen eski bitki ve hayvan kalıntılarından oluřur. Enerji aıėa ıkarmak iin yakılırlar ve elektrik retimi, ulařım ve endstriyel sreler iin birincil enerji kaynaklarıdır. Ancak fosil yakıtların yanması sera gazı salınımına neden olarak iklim deėiřikliėine ve hava kirliliėine katkıda bulunur.

Enerji kaynaklarının yenilenebilir ve yenilenemez olarak sınıflandırılması, evresel etkilerinin, srdrlebilirliklerinin ve uzun vadeli kullanılabilirliklerinin anlařılması aısından nemlidir. Yenilenebilir enerji kaynakları daha temiz ve srdrlebilir bir enerji geleceėi iin potansiyel sunarken, yenilenemeyen kaynaklar evresel kaygılar ve sınırlı kullanılabilirlik ile iliřkilidir.

Yenilenebilir enerjinin başlıca avantajları şunlardır:

7. Çevresel Faydalar: Yenilenebilir enerji kaynakları çok az sera gazı emisyonu üretir veya hiç üretmez, hava kirliliğini azaltır ve iklim değişikliğini hafifletir. Fosil yakıtlara kıyasla daha düşük karbon ayak izine sahiptirler, ekosistemlerin korunmasına ve biyoçeşitliliğin korunmasına yardımcı olurlar.

Yenilenebilir enerji, karbon ayak izinin azaltılması, ekosistemlerin korunması ve biyoçeşitliliğin muhafaza edilmesi açısından büyük önem taşımaktadır. İşte kanıtlarla desteklenen bazı önemli noktalar:

a. Karbon Ayak İzi Azaltımı: Fosil yakıtların aksine, yenilenebilir enerji kaynakları işletme sırasında çok az sera gazı emisyonu üretir veya hiç üretmez. Bu da enerji üretimiyle ilişkili karbon ayak izini önemli ölçüde azaltır (Scherer ve Pfister, 2016). Ülkeler yenilenebilir enerjiye geçiş yaparak iklim değişikliğini hafifletme ve genel karbon emisyonlarını azaltma konusunda önemli ilerleme kaydedebilirler (Holmatov ve Hoekstra, 2020).

b. Ekosistemlerin Korunması: Yenilenebilir enerji projeleri, uygun şekilde planlanıp uygulandığında, habitat tahribatını ve geleneksel enerji kaynaklarıyla ilişkili biyoçeşitlilik kaybını en aza indirebilir (Scherer ve Pfister, 2016). Genellikle arazi temizliğini ve ekosistemlerin bozulmasını içeren fosil yakıt çıkarımının aksine, yenilenebilir enerji projeleri doğal habitatlarla bir arada var olabilir ve biyolojik çeşitliliğin korunmasını destekleyebilir.

c. Biyolojik Çeşitliliğin Korunması: Yenilenebilir enerji teknolojilerinin biyoçeşitlilik üzerindeki etkisi, fosil yakıt çıkarma ve yakmaya kıyasla daha düşüktür. Fosil yakıtlara olan talebi azaltarak yenilenebilir enerji, çeşitli bitki ve hayvan türlerinin hayatta kalması için çok önemli olan ekosistemlerin ve habitatların korunmasına yardımcı olur. Bu durum, biyoçeşitliliğe yönelik artan tehditler ve habitat kaybı karşısında özellikle önemlidir.

d. Sürdürülebilir Kaynak Kullanımı: Güneş, rüzgar ve hidroelektrik enerji gibi yenilenebilir enerji kaynakları, doğal olarak yenilenen kaynaklardan yararlanır. Çıkarılması gereken sonlu fosil yakıtların aksine, yenilenebilir enerji doğal kaynakların korunmasına ve kaynak çıkarma

ile ilişkili çevresel bozulmanın azaltılmasına yardımcı olur. Bu sürdürülebilir kaynak kullanımı, ekosistemlerin ve biyolojik çeşitliliğin uzun vadede korunmasına katkıda bulunur.

e. Çevresel Etkilerin Azaltılması: Yenilenebilir enerji teknolojileri, geleneksel enerji kaynaklarına göre daha düşük çevresel etkilere sahiptir. Örneğin hidroelektrik, fosil yakıt bazlı enerji santrallerine göre daha düşük biyogenik karbon ayak izine sahiptir (Scherer ve Pfister, 2016). Güneş enerjisiyle çalışan elektrikli araçlar, benzinle çalışan geleneksel araçlara kıyasla kilometre başına daha küçük çevresel ayak izine sahiptir (Holmatov ve Hoekstra, 2020). Toplumlar yenilenebilir enerjiyi benimseyerek çevresel ayak izlerini azaltabilir, ekosistemler ve biyoçeşitlilik üzerindeki olumsuz etkileri en aza indirebilir.

Bu noktalar, yenilenebilir enerjinin karbon emisyonlarının azaltılması, ekosistemlerin korunması ve biyolojik çeşitliliğin muhafaza edilmesindeki önemini vurgulamaktadır. Toplumlar, yenilenebilir enerji kaynaklarına geçiş yaparak daha sürdürülebilir ve çevre dostu bir geleceğe katkıda bulunabilirler.

7. Enerji Güvenliği ve Bağımsızlığı: Yenilenebilir enerji kaynakları bol miktarda bulunur ve yaygın olarak dağıtılır, ithal fosil yakıtlara bağımlılığı azaltır. Bu da enerji güvenliğini artırır ve fiyat dalgalanmalarına ve jeopolitik gerilimlere karşı kırılganlığı azaltır.

Enerji güvenliği, bir ülkenin veya bölgenin ihtiyaçlarını karşılamak için enerji kaynaklarının mevcudiyetini ve güvenilirliğini ifade eder (Alsagr ve Hemmen, 2021). Yenilenebilir enerji bağlamında enerji güvenliği, fosil yakıtlara olan bağımlılığı azaltmak ve fiyat dalgalanmaları ile jeopolitik gerilimlere karşı kırılganlığı azaltmak için yenilenebilir enerji kaynaklarının istikrarlı ve tutarlı bir şekilde tedarik edilmesini içerir.

Yenilenebilir enerjideki fiyat dalgalanmaları, teknoloji maliyetlerindeki değişiklikler, hükümet politikaları ve piyasa dinamikleri gibi çeşitli faktörlerden etkilenebilir (Alsagr ve Hemmen, 2021). Yenilenebilir enerji kaynaklarına geçiş, yenilenebilir enerjinin toplam maliyetini etkileyebilecek altyapı ve teknolojiye önemli yatırımlar gerektirmektedir. Bununla birlikte, yenilenebilir enerji teknolojileri ilerlemeye ve ölçeklenmeye devam ettikçe, maliyetlerin

düşmesi ve yenilenebilir enerjiyi geleneksel fosil yakıtlarla daha rekabetçi hale getirmesi beklenmektedir (Alsagr ve Hemmen, 2021).

Jeopolitik gerilimlere karşı kırılganlık, yenilenebilir enerji bağlamında dikkate alınması gereken bir diğer önemli husustur. Çatışmalar, ticari anlaşmazlıklar ve siyasi istikrarsızlık gibi jeopolitik riskler, yenilenebilir enerji kaynaklarının tedarik zincirlerini ve dağıtımını sekteye uğratabilir (Flouros ve ark., 2022). Örneğin, yenilenebilir enerji teknolojileri için gerekli olan kritik mineral ve malzemelerin mevcudiyeti jeopolitik gerilimlerden etkilenebilir ve potansiyel olarak arz kıtlığına ve fiyat dalgalanmalarına yol açabilir (Flouros ve ark., 2022). Ayrıca, jeopolitik faktörler yenilenebilir enerji projeleri için yatırım ortamını etkileyerek yenilenebilir enerji sektörünün genel büyümesini ve gelişimini etkileyebilir (Flouros ve ark., 2022).

Bu zorlukların üstesinden gelmek için yenilenebilir enerji kaynaklarını çeşitlendirmek ve bölgesel iş birliği ve ortak çalışmayı geliştirmek çok önemlidir (Alsagr ve Hemmen, 2021). Ülkeler yenilenebilir enerji karışımını çeşitlendirerek tek bir enerji kaynağına bağımlılığı azaltabilir ve fiyat dalgalanmaları ve jeopolitik gerilimlerle ilişkili riskleri hafifletebilir. Bölgesel iş birliği aynı zamanda kaynakların, uzmanlığın ve altyapının paylaşılmasına yardımcı olarak daha güvenli ve dirençli bir yenilenebilir enerji sistemi sağlayabilir (Alsagr ve Hemmen, 2021).

Yenilenebilir enerji bağlamında enerji güvenliği, fiyat dalgalanmaları ve jeopolitik gerilimlerle ilişkili riskleri azaltırken yenilenebilir enerji kaynaklarının istikrarlı ve güvenilir bir şekilde tedarik edilmesini içerir. Enerji kaynaklarının çeşitlendirilmesi ve bölgesel iş birliği, yenilenebilir enerji sektöründe enerji güvenliğini artırmak için kilit stratejilerdir.

7. Ekonomik Büyüme ve İş Yaratma: Yenilenebilir enerji sektörü ekonomik büyümeyi teşvik etme ve istihdam yaratma potansiyeline sahiptir. Yenilenebilir enerji projelerine yapılan yatırımlar yerel ekonomik kalkınmayı destekleyebilir, özel yatırımları çekebilir ve çeşitli beceri düzeylerinde çok çeşitli istihdam fırsatları yaratabilir.

Yenilenebilir enerjinin ekonomik büyümeyi teşvik etme ve istihdam yaratma potansiyeli olduğu çeşitli çalışmalarla kanıtlanmıştır. Ntanos ve ark. (2018), 25 Avrupa ülkesini incelemiş ve yenilenebilir enerji tüketimi ile ekonomik büyüme arasında, özellikle de yüksek Gayrisafi

Yurt İçi Hasıla'ya (GSYH) sahip ülkelerde pozitif bir korelasyon bulmuştur. Çalışmada, yenilenebilir enerji kaynakları tüketimi, kişi başına düşen GSYH, gayrisafi sabit sermaye oluşumu ve işgücü arasındaki ilişkiyi belirlemek için tanımlayıcı istatistikler, küme analizi ve otoregresif dağıtılmış gecikme (ARDL, Autoregressive Distributed Lag Bound Test) gibi istatistiksel analiz teknikleri kullanılmıştır. Sonuçlar, yenilenebilir enerji tüketiminin uzun vadede ekonomik büyüme ile ilişkili olduğunu göstermektedir.

Kumar ve Majid (2020), Hindistan'daki yenilenebilir enerji sektörüne odaklanmış ve sektörün karşılaştığı çeşitli engelleri tespit etmiştir. Yenilenebilir enerji teknolojilerinin gelişimini teşvik etmek için belirli stratejilerin yanı sıra itme politikaları ve çekme mekanizmalarının bir kombinasyonunu önermişlerdir. Bu stratejiler arasında teknolojik ilerlemeler, düzenleyici politikalar, vergi indirimleri, araştırma ve geliştirme çabaları ve verimlilik artırımları yer almaktadır. Yazarlar ayrıca, vasıfsız işçiler, teknisyenler ve müteahhitler için istihdam yaratmak amacıyla yenilenebilir enerji sektöründeki yatırım fırsatlarının teşvik edilmesinin önemini de tartışmıştır.

Ahmed ve Shimada (2019), yükselen ve gelişmekte olan ekonomilerde yenilenebilir enerji projelerinin başarılı bir şekilde uygulanması için uygun bir politika paketinin benimsenmesinin önemini vurgulamıştır. Sübvansiyonlar, yenilenebilir portföy standartları, düşük faizli krediler, yeşil sertifikalar ve tarife garantileri gibi çeşitli yenilenebilir enerji politikalarının altını çizmişlerdir. Bu politikalar, teknoloji kurulumunun ilk maliyetini azaltmayı, yenilenebilir enerji üretimini teşvik etmeyi ve yenilenebilir kaynaklardan üretilen elektrik için garantili bir fiyat sağlamayı amaçlamaktadır. Yazarlar, yenilenebilir enerji tüketiminin bu ekonomilerde sürdürülebilir ekonomik kalkınmaya katkıda bulunduğunu öne süren bir geri besleme hipotezini destekleyen kanıtlar bulmuşlardır.

Referanslar yenilenebilir enerjinin ekonomik büyümeyi teşvik etme ve istihdam yaratma potansiyeline sahip olduğuna dair kanıtlar sunmaktadır. Çalışmalar, özellikle yüksek GSYH'ye sahip ülkelerde yenilenebilir enerji tüketimi ile ekonomik büyüme arasındaki pozitif korelasyonu vurgulamaktadır. Ayrıca, yenilenebilir enerji sektöründe yatırım fırsatlarını teşvik etmek için uygun politika ve stratejilerin uygulanmasının önemini vurgulamaktadırlar; bu da istihdam yaratılmasına ve sürdürülebilir ekonomik kalkınmaya yol açabilir.

4. Maliyet Rekabetçiliği: Yenilenebilir enerji teknolojilerinin maliyeti son yıllarda hızla düşmekte ve fosil yakıtlarla maliyet açısından giderek daha rekabetçi hale gelmektedir. Güneş ve rüzgar gibi yenilenebilir enerji kaynakları birçok bölgede şebeke paritesine ulaşmıştır, yani geleneksel kaynaklara benzer veya daha düşük maliyetle elektrik üretebilirler.

Fosil yakıtlara kıyasla yenilenebilir enerji teknolojilerinin maliyetinin rekabet edebilirliği, daha sürdürülebilir bir enerji sistemine geçişte büyük ilgi gören bir konudur. Birçok çalışma bu konuyu incelemiş ve yenilenebilir enerji teknolojilerinin maliyet rekabetçiliğini destekleyen kanıtlar bulmuştur.

Adlong (2012) tarafından yapılan bir çalışma, yenilenebilir enerji teknolojilerinin hızlı gelişimini ve bunların çevre eğitimcileri üzerindeki etkilerini vurgulamaktadır. Çalışma, birçok yenilenebilir enerji teknolojisinin maliyetlerinin 10-15 yıl içinde fosil yakıtlarla rekabet edebilir hale gelmesinin beklendiğini ve bazı tesislerin halihazırda maliyet açısından rekabet edebilir durumda olduğunu belirtmektedir. Bu da yenilenebilir enerji teknolojilerinin giderek daha uygun maliyetli hale geldiğini ve maliyet açısından fosil yakıtlarla rekabet edebileceğini göstermektedir.

Kalair ve ark. (2020) tarafından yapılan bir başka çalışma, fosil yakıtlardan yenilenebilir enerjiye geçişte enerji depolama sistemlerinin rolünü tartışmaktadır. Çalışma, enerji depolama cihazlarının güneş ve rüzgâr gibi yenilenebilir enerji kaynaklarının kesintili doğasını hesaba katabileceğini vurgulamaktadır. Bu durum, enerji depolama sistemlerinin entegre edilmesinin, yenilenebilir enerji teknolojilerinin kesintili yapısını ele alarak ve güvenilir bir enerji arzı sağlayarak bu teknolojilerin rekabet gücünü artırabileceğine işaret etmektedir.

Ayrıca, Khaw ve Ni (2021) tarafından yapılan çalışma, gelişmekte olan Asya ülkelerinde fosil yakıt fiyatları, karbondioksit emisyonları ve yenilenebilir enerji kapasitesi arasındaki ilişkiyi incelemektedir. Çalışma, yenilenebilir enerji kapasitesinin karbondioksit emisyonlarının azaltılması üzerindeki olumlu etkisine dair kanıtlar sunmaktadır. Bu durum, yenilenebilir enerji teknolojilerinin fosil yakıtlarla potansiyel olarak maliyet açısından rekabet edebilirken çevresel faydalar da sunabileceğini göstermektedir.

Çok sayıda çalışma yenilenebilir enerji teknolojilerinin fosil yakıtlarla maliyet açısından giderek daha rekabetçi hale geldiği fikrini desteklemektedir. Bu teknolojilerin hızlı gelişimi ve enerji depolama sistemlerindeki ilerlemeler, maliyet rekabetçiliğine katkıda bulunmaktadır. Yenilenebilir enerji teknolojileri gelişmeye ve ölçeklenmeye devam ettikçe, fosil yakıtlara karşı uygulanabilir ve ekonomik açıdan rekabetçi bir alternatif sunma potansiyeline sahiptir.

5. Enerji Çeşitliliği ve Esneklik: Enerji karışımının yenilenebilir kaynaklarla çeşitlendirilmesi, tek bir enerji kaynağına olan bağımlılığı azaltarak enerji direncini ve istikrarını artırır. Çatı üstü güneş panelleri gibi dağıtılmış yenilenebilir enerji sistemleri, yaygın elektrik kesintisi riskini azaltarak şebeke direncini de artırabilir.

Yenilenebilir enerji, tek bir enerji kaynağına bağımlılığı azaltarak enerji direncini ve istikrarını artırmada çok önemlidir. Bu, enerji sistemlerinin adaptif kapasitesini ve direncini artıran enerji kaynaklarının çeşitlendirilmesi yoluyla elde edilir (Molyneaux ve ark., 2016).

Enerji sistemlerinde esneklik, artıklık ve çeşitlilik gibi parametrelerle ölçülür. Bu parametreler mevcut olduğunda, esneklik artar ve ekonomik istikrar artar (Molyneaux ve ark., 2016). Güneş fotovoltaik ve rüzgar enerjisi gibi yenilenebilir enerji kaynaklarının kullanılması, enerji karışımının çeşitlendirilmesine katkıda bulunarak fosil yakıtlara olan bağımlılığı azaltmakta ve genel enerji sisteminin dayanıklılığını artırmaktadır (Pagliaro, 2019).

Yenilenebilir enerjinin esneklik ve istikrar açısından faydaları, enerji kaynaklarının çeşitlendirilmesiyle sınırlı değildir. Yenilenebilir enerji hibrit sistemlerinin (REHS, Renewable energy hybrid system) esnekliğini ölçmek ve paraya çevirmek için bir metodoloji önermektedir (Anderson ve ark., 2018). Çalışmaları, geleneksel yedek dizel jeneratörler yerine REHS'nin uygulanmasının kesinti beka kabiliyetini önemli ölçüde artırabileceğini ve katma değer sağlayabileceğini göstermektedir. Örneğin, New York'taki binalar üzerinde yapılan bir vaka çalışmasında, REHS'nin uygulanması, kesintiden kurtulma miktarını iki katına çıkarmış ve 781.200 \$ katma değer sağlamıştır (Anderson ve ark., 2018). Bu durum, yenilenebilir enerjinin dayanıklılık açısından potansiyel ekonomik faydalarını vurgulamaktadır.

Ayrıca, geleneksel baz yük santrallerine kıyasla yenilenebilir üretimin dağıtık yapısı, enerji sisteminin dayanıklılığına katkıda bulunmaktadır (Anderson ve ark., 2018). Yenilenebilir

enerjinin merkezi olmayan yapısı, tek bir konumdaki kesintilere karşı kırılganlığı azalttığı için daha esnek ve sağlam bir enerji altyapısı sağlar.

Yenilenebilir enerjiyi eleştirenler, güneş ışığı ve rüzgârın kesintili olmasının enerji üretimini planlamada ve talebi karşılamada zorluklar yarattığını savunmaktadır. Ancak teknolojiye ve endüstriyel ilerlemedeki gelişmeler bu endişeleri gidermiştir. Kamu ölçeğinde güneş ve rüzgâr enerjisi üretimi, geleneksel termoelektrik enerji üretimiyle rekabet edebilir hale gelmiştir ve enerji depolama sistemlerinin geliştirilmesiyle kesinti sorunu hafifletilmektedir (Pagliaro, 2019).

Yenilenebilir enerji, tek bir enerji kaynağına bağımlılığı azaltarak enerji direncini ve istikrarını artırmada hayati önem taşımaktadır. Yenilenebilir enerjinin yaygınlaştırılması yoluyla enerji kaynaklarının çeşitlendirilmesi, enerji sistemlerinin uyum kapasitesini ve dayanıklılığını artırmaktadır. Ayrıca, yenilenebilir enerji üretiminin dağıtık yapısı ve teknolojiye ilerlemeler enerji sisteminin genel dayanıklılığına katkıda bulunmaktadır. Yenilenebilir enerjinin dayanıklılık açısından ekonomik faydaları da yenilenebilir enerji 1000 sistemleri tarafından sağlanan dayanıklılığın ölçülmesi ve parasallaştırılmasıyla ortaya konmuştur. Genel olarak yenilenebilir enerji, daha dirençli ve istikrarlı bir enerji geleceğinin inşasında kilit bir bileşendir.

6. Sağlık Faydaları: Yenilenebilir enerji kaynaklarının kullanımı hava ve su kirliliğini azaltarak halk sağlığı sonuçlarının iyileşmesini sağlar. Yenilenebilir kaynaklar, fosil yakıtların yanmasını temiz enerji ile değiştirerek solunum yolu hastalıklarını, kardiyovasküler sorunları ve kirlilikle ilişkili diğer sağlık sorunlarını azaltmaya yardımcı olur.

Yenilenebilir enerji, halk sağlığını iyileştiren ve kirlilikle ilgili sağlık sorunlarını azaltan çok sayıda çevresel faydaya sahiptir. İşte kanıtlarla desteklenen bazı önemli noktalar:

a. Hava Kirliliğinin Azaltılması: Yenilenebilir enerji kaynakları fosil yakıtları yakmadan elektrik üreterek sülfür dioksit, nitrojen oksitler ve partikül madde gibi hava kirlleticilerin emisyonunu önemli ölçüde azaltır. Bu kirleticiler solunum yolu hastalıklarına, kardiyovasküler sorunlara ve diğer sağlık sorunlarına neden olmaktadır (Amk ve Ms, 2021).

b. Sera Gazı Emisyonlarının Azaltılması: Yenilenebilir enerji teknolojileri, atmosfere önemli miktarda karbondioksit gibi sera gazları salmadan elektrik üretir. Yenilenebilir enerji, sera gazı emisyonlarını azaltarak, ısıya bağlı hastalıklar, vektör kaynaklı hastalıklarda artış, gıda ve su kaynaklı hastalıklar gibi olumsuz sağlık etkileri olan iklim değişikliğinin azaltılmasına yardımcı olur (Gallagher ve Holloway, 2020).

c. İç Mekan Hava Kalitesinin İyileştirilmesi: Geleneksel biyokütle yakıtlarının yemek pişirme ve ısınma için yaygın olarak kullanıldığı gelişmekte olan ülkelerde, biyogaz veya geliştirilmiş ocaklar gibi daha temiz ve daha verimli yenilenebilir enerji kaynaklarına geçiş, iç mekan hava kalitesini önemli ölçüde artırabilir. Bu da özellikle iç mekan hava kirliliğine en çok maruz kalan kadınlar ve çocuklar arasında solunum yolu hastalıkları riskini azaltır (Şenyapar, 2023).

d. Su Kirliliğinde Azalma: Güneş ve rüzgar enerjisi gibi yenilenebilir enerji teknolojileri, soğutma için suya ihtiyaç duyan geleneksel enerji santrallerinin aksine, elektrik üretimi için suya ihtiyaç duymaz. Su kullanımını azaltarak yenilenebilir enerji, su kaynaklarının korunmasına yardımcı olur ve soğutma suyu ve atık su deşarjı yoluyla su kütlelerinin kirlenmesini azaltır (Güney, 2019).

e. Ekosistemlerin ve Biyoçeşitliliğin Korunması: Uygun şekilde planlandığında ve uygulandığında, yenilenebilir enerji projeleri habitat tahribatını ve geleneksel enerji kaynaklarıyla ilişkili biyolojik çeşitlilik kaybını en aza indirebilir. Yenilenebilir enerji, madencilik ve sondaj gibi arazi yoğun faaliyetlere olan ihtiyacı azaltarak ekosistemlerin ve bunlara bağlı olan türlerin korunmasına yardımcı olur (Güney, 2019).

Sonter ve ark. (2020), yenilenebilir enerji üretimi nedeniyle madenciliğin biyoçeşitliliğe yönelik tehditlerinin potansiyel olarak kötüleşmesine odaklanmıştır. Dünya kara yüzeyinin 50 milyon km² 'sini etkileyen birçok madencilik alanının yenilenebilir enerji üretimi için gerekli malzemeleri hedeflediğini tespit etmişlerdir. Bu madencilik alanları genellikle korunan alanlar, kilit biyoçeşitlilik alanları ve kalan vahşi doğayla örtüşmektedir. Stratejik planlama yapılmadığı takdirde, yenilenebilir enerji üretimiyle bağlantılı olarak biyoçeşitliliğe yönelik madencilik tehditleri, fosil yakıt kullanımının azaltılmasıyla hafifletilen tehditleri aşabilir.

f. Sürdürülebilir Kaynak Kullanımı: Güneş, rüzgar ve hidroelektrik enerji gibi yenilenebilir enerji kaynakları, doğal olarak yenilenen kaynaklardan yararlanır. Sınırlı olan ve çıkarılması gereken fosil yakıtların aksine, yenilenebilir enerji doğal kaynakların korunmasına ve kaynak çıkarma ile ilişkili çevresel bozulmanın azaltılmasına yardımcı olur (Güney, 2019).

g. Sürdürülebilir Kalkınmanın Teşvik Edilmesi: Yenilenebilir enerjinin benimsenmesi, özellikle kırsal ve uzak bölgelerde temiz ve uygun fiyatlı enerjiye erişim sağlayarak sürdürülebilir kalkınmaya katkıda bulunur. Güvenilir elektriğe erişim sağlık hizmetlerini iyileştirir, eğitimi kolaylaştırır ve ekonomik faaliyetleri destekleyerek yaşam koşullarını ve genel refahı iyileştirir (Liu ve Zhong, 2022).

Yenilenebilir enerjinin bu çevresel faydaları, solunum yolu hastalıkları, kardiyovasküler sorunlar ve kirlilikle ilgili diğer sağlık sorunlarının azaltılmasındaki önemli rolünü vurgulamaktadır. Toplular, yenilenebilir enerji kaynaklarına geçiş yaparak halk sağlığı sonuçlarını iyileştirebilir, iklim değişikliğini hafifletebilir ve daha sürdürülebilir ve dirençli bir gelecek yaratabilir.

7. Teknolojik Yenilik ve Araştırma: Yenilenebilir enerji teknolojilerinin geliştirilmesi ve yaygınlaştırılması, enerji sektöründe inovasyonu ve araştırmayı teşvik eder. Bu da enerji depolama, şebeke entegrasyonu ve diğer alanlarda ilerlemelere yol açarak sadece yenilenebilir enerji sektörüne değil ekonominin diğer sektörlerine de fayda sağlayabilir.

Yenilenebilir enerji teknolojilerinin geliştirilmesi ve yaygınlaştırılması, enerji sektöründeki inovasyon ve araştırmaları önemli ölçüde etkilemiştir. Çeşitli çalışmalar bu ilişkiyi araştırmış ve bu etkinin çeşitli yönlerine ilişkin iç görüler sağlamıştır.

Khan ve Su (2022) tarafından yapılan bir çalışma, teknolojik yenilik ile yenilenebilir enerjiye geçiş arasındaki tamamlayıcılığı incelemektedir. Yazarlar, yenilenebilir enerjinin genişlemesinin, yenilikçi yenilenebilir projeler için sübvansiyonları azaltan finansal kriz tarafından engellendiğini vurgulamaktadır. Bununla birlikte, yenilenebilir enerji teknolojilerinin tesis verimliliğini ve tutarlı üretimi artırdığını da belirtiyorlar. Fosil enerjiden daha pahalı olmasına rağmen, düşük karbonlu teknolojilerde yükselen bir eğilim söz konusudur ve bu da yenilenebilir enerji sektöründe inovasyona odaklanıldığını göstermektedir.

Xing ve ark. (2023) tarafından yapılan bir başka çalışma, sürdürülebilir yenilenebilir enerji geliştirme politikaları ve teknolojik inovasyona odaklanmaktadır. Yazarlar, yenilenebilir enerji gelişimi ile teknolojik yenilik arasında pozitif bir ilişki bulmuşlardır. Bu ilişkinin farklı ülkelerde ve ülke gruplarında gözlemlendiğini vurgulamaktadırlar. Bu durum, yenilenebilir enerji teknolojilerinin geliştirilmesi ve yaygınlaştırılmasının enerji sektöründe küresel inovasyonu teşvik ettiğini göstermektedir.

Li ve ark. (2021), küresel yenilenebilir enerji inovasyon sistemlerindeki bilgi akışlarını araştırmıştır. Farklı yenilenebilir enerji teknolojisi inovasyon sistemlerinden gelen bilgiyi birleştirmek için teknolojik ve coğrafi mesafeler arasında köprü kurmanın önemini vurgulamaktadırlar. Yazarlar, yenilenebilir enerji teknolojilerinin karmaşık olduğunu ve çeşitli teknolojilerden bilgi girdisi gerektirdiğini savunmaktadır. Ayrıca, yenilenebilir enerji teknolojilerindeki bilginin ülkeler arasında eşit olmayan dağılımını vurgulayarak uluslararası bilgi akışının öneminin altını çizmektedirler.

Ayrıca, doğrudan yabancı yatırımın (DYY) yenilenebilir enerji teknolojisi yayılımı üzerindeki etkisi (Liu ve ark., 2016) tarafından yapılan bir çalışmada incelenmiştir. Yazarlar, teknoloji yayılımında teknoloji özümseme kapasitesinin ve marka etkisinin çok önemli olduğunu bulmuşlardır. Ürün, süreç ve organizasyonel inovasyonun Çin'in enerji endüstrisi performansı üzerindeki etkilerini değerlendirerek, DYY'nin yenilenebilir enerji teknolojisi yayılımındaki olumlu etkilerini vurgulamaktadırlar.

Sonuç olarak, yenilenebilir enerji teknolojilerinin geliştirilmesi ve yaygınlaştırılması, enerji sektöründeki inovasyon ve araştırmaları önemli ölçüde etkilemiştir. Bu etkiler arasında tesis verimliliğindeki iyileşmeler, istikrarlı üretim ve küresel olarak teknolojik yeniliğin teşvik edilmesi yer almaktadır. Ayrıca, teknolojik ve coğrafi mesafenin kapatılması ve teknoloji yayılımında DYY'nin rolü, yenilenebilir enerji inovasyon sisteminde önemli faktörler olarak tanımlanmıştır.

Bu avantajlar, çevresel zorlukların ele alınmasında, sürdürülebilir kalkınmanın teşvik edilmesinde ve daha esnek ve adil bir enerji sistemi oluşturulmasında yenilenebilir enerjinin önemini vurgulamaktadır.

Hazırlamış olduğumuz tez çalışmamızda, çok kısa vadeli rüzgar hızı tahmininde başarımlı yüksek olacak şekilde, ikincil ayrıştırılmalı ve dalgacık sinir ağı ile oluşturulmuş bir 14hibrit model önerisinde bulunduk. Bu öneri doğrultusunda, popüler olarak kullanılan dört adet ayrıştırma modeli ile ikili olarak on altı adet ayrıştırma çifti ve üç tanesi yapay sinir ağı aktivasyon fonksiyonu, on üç tanesi dalgacık aktivasyon fonksiyonu olacak şekilde toplam on altı aktivasyon fonksiyonu ile 256 adet hibrit model oluşturulmuştur. Bu modeller ile dört mevsimin orta ayları için simülasyonlar yapılmış, ardından bu dört ayın sonuçları doğrultusunda başarımlı yüksek olan 48 model ile yılın diğer sekiz ayı simüle edilmiştir. Bulduğumuz sonuçlar, Ampirik Mod Ayrıştırması türevi olan CEEMDAN yöntemi ile Değişken Mod Ayrıştırma yönetimi (VMD) ile oluşturulan ikili ayrıştırma modelinin, SLOG2 dalgacık aktivasyon fonksiyonu sinir ağı ile oluşturulan hibrit tahmin modelinin yüksek başarımlı tahminler gerçekleştirdiği doğrultusundadır.

Tezimizin bir sonraki bölümü olan “Kuramsal Temeller”de, çalışmamızda bilimsel temeli olan rüzgar hızı ve gücü arasındaki ilişki ve rüzgar hızı tahmininin önemi üzerinde durulmuştur. Rüzgar hızı tahmininde kullanılan başlıca yöntemler hakkında bilgilendirmeler yapılmıştır. Ayrıca, hibrit model önerimizde kullanmış olduğumuz yöntemler hakkında kuramsal bilgiler verilmiştir.

2. KURAMSAL TEMELLER

2.1. Rüzgar Hızı ve Rüzgar Gücü Arasındaki İlişki

Rüzgar hızı ve rüzgar gücü arasındaki ilişki, rüzgar enerjisinin anlaşılması ve kullanılmasında çok önemli bir faktördür. Rüzgar hızı, rüzgar türbinleri tarafından üretilebilecek güç miktarını doğrudan etkiler.

Wanninkhof'a (1992) göre, rüzgar hızı ile okyanus üzerindeki gaz transferi arasında ikinci dereceden bir ilişki vardır. Bu referans gaz alışverişine odaklansa da, rüzgar hızı ve diğer atmosferik süreçler arasındaki ilişki hakkında fikir vermektedir. Yazar, okyanus üzerindeki rüzgar hızı dağılımlarının genellikle Weibull dağılım fonksiyonları olarak ifade edildiğini ve izotropik rüzgarlar için Weibull dağılımının bir çözümünün Rayleigh olasılık dağılım fonksiyonu olduğunu belirtmektedir. Bu, rüzgar hızının olasılık dağılım fonksiyonları kullanılarak modellenebileceğini ve bunun rüzgar gücünü tahmin etmede yararlı olabileceğini göstermektedir.

Wang ve ark. (2020), bulut modeline dayalı rüzgar gücü için bir tahmin yöntemi önermiştir. Rüzgar hızı ve gücü olasılık dağılımlarının düzensiz ve belirsiz olabileceğinden bahsetmektedirler. Bunu ele almak için, tepe noktasını güncellemek ve modelin sağlamlığını artırmak için L2 norm teorisini tanıtmışlardır. Bu, rüzgar hızının olasılık dağılımını analiz ederek rüzgar gücünün tahmin edilebileceğini göstermektedir. Yazarlar ayrıca rüzgar gücü tahmini için destek vektör makineleri ve Bayesian öğrenme modellerinin kullanımından bahsederek rüzgar hızı ve rüzgar gücü arasındaki ilişkiyi daha da vurgulamıştır.

Wang ve ark. (2020) tarafından yapılan bir başka çalışmada, rüzgar hızı zaman kayması özellikleri için bir değerlendirme yöntemi önerilmiştir. Yazarlar, rüzgar hızı dizileri arasındaki zamansal ilişkiyi ve hız değişimini niceliksel olarak tanımlamanın önemini vurgulamıştır. Zaman kayması özelliklerini ölçmek için gecikme süresi ve bozulma hızı gibi değerlendirme indeksleri sunarlar. Bu, rüzgar hızı değişimlerinin rüzgar enerjisi üretiminin zamanlamasını ve süresini etkileyebileceğini göstermektedir.

Genel olarak, referanslar rüzgar hızı ve rüzgar gücünün yakından ilişkili olduğunu göstermektedir. Rüzgar hızı, olasılık dağılım fonksiyonları kullanılarak modellenabilir ve

rüzgar hızındaki değişimler, rüzgar türbinleri tarafından üretilen gücün zamanlamasını ve miktarını etkileyebilir. Rüzgar hızı ve rüzgar gücü arasındaki ilişkiyi anlamak, rüzgar enerjisi sistemlerini optimize etmek ve güç çıkışını tahmin etmek için çok önemlidir.

2.2. Rüzgar Hızı Tahmininde Doğruluğun Önemi

Rüzgar hızının doğru tahmin edilmesi birkaç nedenden dolayı önemlidir. İlk olarak, doğru rüzgar hızı tahmini rüzgar türbinlerinin verimli çalışması için çok önemlidir. Rüzgar türbinleri belirli bir rüzgar hızı aralığında en iyi şekilde çalışacak şekilde tasarlanmıştır. Rüzgar hızı olduğundan fazla tahmin edilirse, türbin aşırı yüklerle maruz kalabilir, bu da potansiyel hasara veya kullanım ömrünün kısılmasına yol açabilir. Öte yandan, rüzgar hızı düşük tahmin edilirse, türbin istenen çıktıyı karşılamak için yeterli güç üretemeyebilir. Bu nedenle, doğru rüzgar hızı tahmini, rüzgar türbinlerinin optimum aralıkta çalışmasını sağlayarak enerji üretimini en üst düzeye çıkarır ve potansiyel hasarı en aza indirir (Østergaard ve ark., 2007).

İkinci olarak, doğru rüzgar hızı tahmini hava tahmini ve iklim modellemesi için gereklidir. Rüzgar hızı, bulut oluşumu, yağış ve sıcaklık dağılımı gibi çeşitli atmosferik süreçleri etkilediği için hava tahmin modellerinde önemli bir parametredir. Doğru rüzgar hızı tahmini, meteorologların hava durumu modelleri hakkında daha kesin tahminler yapmasına olanak tanır; bu da tarım, havacılık ve afete hazırlık gibi çeşitli uygulamalar için çok önemlidir. Ayrıca, doğru rüzgar hızı verileri, araştırmacıların uzun vadeli iklim eğilimlerini ve değişkenliğini anlamalarına ve tahmin etmelerine yardımcı olduğu için iklim modellemesi için gereklidir (Shimada ve Ohsawa, 2011).

Ayrıca, doğru rüzgar hızı tahmini, açık deniz rüzgar çiftlikleri ve açık deniz petrol ve gaz arama gibi açık deniz operasyonları için önemlidir. Açık deniz ortamları, karadaki konumlara kıyasla daha zorlu ve karmaşık rüzgar koşulları ile karakterize edilir. Doğru rüzgar hızı tahmini, açık deniz rüzgar türbinlerinin tasarımı ve işletimi için gereklidir, yapısal bütünlüklerini ve optimum performanslarını sağlar. Açık deniz petrol ve gaz operasyonları söz konusu olduğunda, doğru rüzgar hızı tahmini, sondaj kulelerinin konumlandırılması ve aşırı hava olaylarıyla ilişkili potansiyel risklerin değerlendirilmesi gibi güvenlik hususları için çok önemlidir (Shimada ve Ohsawa, 2011).

Sonuç olarak, doğru rüzgar hızı tahmini, rüzgar türbini işletimi, hava tahmini, iklim modellemesi ve açık deniz operasyonları dahil olmak üzere çeşitli uygulamalar için önemlidir. Rüzgâr türbinlerinin verimli ve güvenli çalışmasını sağlar, hava tahminlerini iyileştirir, iklim modellemesini geliştirir ve açık deniz faaliyetlerini destekler. Bu nedenle, doğru rüzgar hızı tahmini enerji üretimini optimize etmek, güvenliği artırmak ve atmosferin bilimsel anlayışını iletirmek için gereklidir (Østergaard ve ark., 2007; Shimada ve Ohsawa, 2011).

2.3. Rüzgar Hızı Tahmininde Kullanılan Yöntemler

Tahmin yönteminin seçiminin mevcut veriler, hesaplama kaynakları, tahmin ufku ve uygulamanın özel gereksinimleri dahil olmak üzere çeşitli faktörlere bağlı olduğunu belirtmek önemlidir. Araştırmacılar ve tahminciler, mümkün olan en iyi kısa vadeli rüzgar hızı tahminlerini elde etmek için genellikle bu yöntemlerin bir kombinasyonunu kullanırlar.

- Sayısal Hava Tahmini (NWP, Numerical Weather Prediction)
- İstatistiksel Yöntemler
- Makine Öğrenimi
- Topluluk Yöntemleri
- Hibrit Yaklaşımlar

2.3.1. Sayısal Hava Tahmini

Rüzgar hızı tahmini, yenilenebilir enerji üretimi, hava tahmini ve bina tasarımı gibi çeşitli alanlarda çok önemli bir husustur. Rüzgar hızının doğru tahmini arazi, engeller, sıcaklık ve basınç gibi fiziksel faktörlerin dikkate alınmasını gerektirir. Bu zorluğun üstesinden gelmek için çeşitli yaklaşımlar önerilmiştir.

Bu yaklaşımlardan biri, Østergaard ve ark. (2007) tarafından, etkin rüzgar hızı için önerilmiş bir tahmin yöntemidir. Enerji üretimini en üst düzeye çıkarmak için rüzgar türbinlerinin eğim açısını optimize etmeye odaklanmışlardır. Rüzgar hızı ve türbin özellikleri gibi faktörleri göz önünde bulundurarak, etkin rüzgar hızını tahmin etmek için matematiksel bir optimizasyon modeli geliştirmişlerdir. Bu yaklaşım, rüzgar hızı tahminine dayalı olarak rüzgar türbini performansının optimize edilmesine yönelik içgörüler sağlamaktadır.

Bu yaklaşımlardan biri, (Chen ve ark., 2018) tarafından gösterildiği gibi derin öğrenme tekniklerinin kullanılmasıdır. Rüzgar hızını tahmin etmek için evrişimsel sinir ağlarını (CNN'ler) ve çok katmanlı bir algılayıcıyı (MLP, Multi-Layer Perceptron) entegre eden birleşik bir çerçeve önermektedirler. CNN'ler uzamsal özellikleri çıkarırken, MLP bu özellikler arasındaki zamansal bağımlılıkları yakalar. Hem mekansal hem de zamansal yönleri dikkate alarak, modelleri doğru rüzgar hızı tahminine ulaşmaktadır.

Bir başka yaklaşım da (Winstral ve ark., 2009) tarafından tartışıldığı gibi, rüzgar hızlarının heterojen arazi üzerindeki dağılımını içerir. Dağ manzaraları üzerinde rüzgarın yüksek mekansal değişkenliğini vurgulamaktadırlar, bu da kütle ve enerji akışlarında güçlü gradyanlar yaratabilir. Bu değişkenliği yakalamak için, rüzgar modellerini belirleyen karmaşık süreçleri hesaba katan dağıtılmış bir rüzgar modeli geliştirmişlerdir. Geliştirdikleri model, rüzgar varyansını açıklamada ve sahalar arasındaki rüzgar hızı farklılıklarını yakalamada umut verici sonuçlar ortaya koymaktadır.

Buna ek olarak, (Chen ve ark., 2018) tarafından gösterildiği gibi derin öğrenme tekniklerinin kullanılmasıdır. Rüzgar hızını tahmin etmek için evrişimsel sinir ağlarını (CNN'ler) ve çok katmanlı bir algılayıcıyı (MLP, Multi-Layer Perceptron) entegre eden birleşik bir çerçeve önermişlerdir. CNN'ler uzamsal özellikleri çıkarırken, MLP bu özellikler arasındaki zamansal bağımlılıkları yakalar. Hem mekansal hem de zamansal yönleri dikkate alarak, modelleri doğru rüzgar hızı tahminine ulaşmıştır.

Genel olarak, bu referanslar arazi, engeller, sıcaklık ve basınç gibi fiziksel faktörleri göz önünde bulundurarak rüzgar hızını tahmin etmek için farklı yaklaşımları vurgulamaktadır. Derin öğrenme teknikleri, dağıtık rüzgar modelleri ve matematiksel optimizasyon modellerinin kullanımı, çeşitli uygulamalarda doğru rüzgar hızı tahminine katkıda bulunur. Araştırmacılar ve uygulayıcılar, bu faktörleri rüzgar hızı tahmin modellerine dahil ederek rüzgar enerjisi üretimi, hava tahmini ve bina tasarımının verimliliğini ve güvenilirliğini artırabilirler.

Verilen referanslara dayanarak, arazi, engeller, sıcaklık ve basınç gibi fiziksel faktörleri kullanarak rüzgar hızı tahmini için bazı ilgili yöntemler aşağıda verilmiştir. Winstral ve ark. (2009), heterojen arazi üzerinde rüzgar hızlarını dağıtmak için etkili bir yöntem önermiştir. Çalışma, dağ manzaraları üzerindeki rüzgarın yüksek mekansal değişkenliğini ve bunun kar

dağılımı üzerindeki etkisini yakalamaya odaklanmıştır. Yazarlar, tüm rüzgar değişkenliğini yakalamak için bir rüzgar sensörleri ağı kullanmış ve mevcut sensör verilerine dayanarak farklı konumlardaki rüzgar hızlarını tahmin etmek için modeller geliştirmiştir (Winstral ve ark., 2009).

Knudsen ve ark. (2011), bir rüzgar çiftliğindeki türbin konumlarında rüzgar hızı için tahmin modelleri geliştirmiştir. Çalışma, bir rüzgar çiftliğindeki türbinler ve rüzgar alanı arasındaki ilişkiyi anlamayı amaçlamıştır. Yazarlar, rüzgar türbinlerinde yorgunluk ve üretim arasındaki dengeyi optimize etmek için çok önemli olan rotor diski üzerindeki etkili rüzgar hızını (EWS, Effective Wind Speed) tahmin etmek için farklı modeller araştırmışlardır (Knudsen ve ark., 2011).

Ingenhorst ve arkadaşları (2021), karmaşık araziler üzerindeki uzamsal rüzgar hızı dağılımının havadan ölçümü için bir yöntem sunmuştur. Çalışma, karmaşık arazi üzerindeki rüzgar hızlarını araştırmak için hesaplamalı akışkanlar dinamiği (CFD, Computational Fluid Dynamics) simülasyonlarını kullanmaya odaklanmıştır. Yazarlar, CFD simülasyonlarıyla ilişkili zorlukların ve belirsizliklerin altını çizmiş ve doğru saha değerlendirmesi için kapsamlı ölçümlerin önemini vurgulamıştır (Ingenhorst ve ark., 2021).

Østergaard ve arkadaşları (2007) etkili rüzgar hızının tahmini için bir yöntem önermiştir. Çalışma, rüzgar türbini kontrol algoritmaları için çok önemli bir parametre olan etkin rüzgar hızını tahmin etmeyi amaçlamıştır. Yazarlar, rotor hızını ve aerodinamik torku tahmin etmek için birleşik bir durum ve girdi gözlemcisi geliştirmiş ve bunlar daha sonra etkin rüzgar hızını hesaplamak için kullanılmıştır (Østergaard ve ark., 2007).

Bu referanslar, arazi, engeller, sıcaklık ve basınç gibi fiziksel faktörleri göz önünde bulundurarak rüzgar hızı tahmini için çeşitli yöntemler hakkında fikir vermektedir. Bu yöntemler, rüzgarın mekansal değişkenliğini yakalamayı, türbinler ve rüzgar alanı arasındaki ilişkiyi anlamayı ve rüzgar türbini kontrolü ve optimizasyonu için etkili rüzgar hızını tahmin etmeyi amaçlamaktadır.

Sayısal Hava Tahmini rüzgar hızı tahmini için fiziksel bir yaklaşımdır. Rüzgâr hızı tahmini, meteoroloji ve hava tahmininde çok önemli bir husustur. NWP modelleri rüzgar hızlarını

tahmin etmek için yaygın olarak kullanılır, ancak doğrulukları değişebilir. NWP modellerinden elde edilen rüzgar hızlarını uydu gözlemleri ile karşılaştırmak ve NWP rüzgar hızı tahminlerinin doğruluğunu artırmak için çeşitli çalışmalar yapılmıştır.

Wallcraft ve ark. (2009) tarafından yapılan bir çalışmada, küresel okyanus üzerinde uydulardan ve NWP ürünlerinden elde edilen aylık ortalama 10 m rüzgar hızları karşılaştırılmıştır. Çalışma, NWP ürünlerinin standart analiz dönemi boyunca uydu rüzgarlarına göre neredeyse mükemmel beceriye sahip olduğunu bulmuştur. Bu da NWP modellerinin okyanus üzerindeki rüzgâr hızlarına ilişkin doğru tahminler sağlayabileceğini göstermektedir.

Bununla birlikte, NWP modelleri genellikle çözülmemiş orografinin etkilerini parametrize eder, bu da özellikle yüksek zeminli alanlarda rüzgar hızı tahminlerinde yanlışlıklara yol açar. Howard ve Clark (2007), gözlemlenen ve modellenen rüzgar hızlarını uzlaştırmak için NWP rüzgar hızı tahminlerini düzeltmek ve ölçek küçültmek için bir yöntem önermiştir. Bu yöntem, yapay olarak artan yüzey gerilimini ve çözülmemiş zirveler üzerindeki hızlanma için modelleme eksikliğini ele almaktadır. Bu yaklaşım, gözlemlenen rüzgar hızlarını da dahil ederek, karmaşık arazilere sahip bölgelerde NWP rüzgar hızı tahminlerinin doğruluğunu artırabilir.

NWP modellerinin uydu gözlemleri ile karşılaştırılmasına ek olarak, olasılıksal rüzgar hızı tahminleri, NWP tahminleri topluluğuna dayalı olarak oluşturulabilir. Eide ve ark. (2017), rüzgar hızı ve yönünü kullanarak rüzgar hızı topluluğu tahminleri için bir Bayesian Model Ortalaması yaklaşımı geliştirmiştir. Bu yaklaşım, rüzgar hızına ek olarak birden fazla NWP değişkenini dikkate alır ve bu da topluluk tahminlerinin kalibrasyonunu iyileştirebilir. Ek NWP değişkenlerinin dahil edilmesiyle, rüzgar hızı topluluk tahminlerinin doğruluğu artırılabilir.

Kara ve ark. (2008) tarafından yapılan bir başka çalışma, küresel okyanus üzerinde kara-deniz sınırlarına yakın 10 m rüzgar hızlarının doğruluğuna odaklanmıştır. Çalışmada üç NWP merkezinden ve iki uydu tabanlı üründen elde edilen rüzgarlar analiz edilmiştir. Analiz sonuçları, bu bölgelerdeki 10 m rüzgar hızlarının güvenilirliğine ilişkin bilgiler sağlamıştır. Bu bilgi, kara-deniz sınırlarına yakın NWP rüzgar hızı tahminlerinin doğruluğunu artırabilir.

Sonuç olarak, NWP modelleri ile rüzgar hızı tahminlerinin doğruluğunu değerlendirmek ve geliştirmek için çeşitli çalışmalar yapılmıştır. Bu çalışmalar NWP rüzgar hızlarını uydu gözlemleriyle karşılaştırmış, NWP rüzgar hızı tahminlerini düzeltmek ve ölçek küçültmek için yöntemler önermiş, topluluk NWP tahminlerini kullanarak olasılıksal rüzgar hızı tahminleri geliştirmiş ve kara-deniz sınırlarına yakın NWP rüzgar hızlarının doğruluğunu analiz etmiştir. Meteorologlar ve hava tahmincileri bu çalışmalardan elde edilen bulguları birleştirerek NWP modelleri ile rüzgar hızı tahminlerinin doğruluğunu artırabilirler.

Rüzgar hızı tahmini genellikle verileri analiz etmek ve yorumlamak için istatistiksel yöntemlerin kullanılmasını içerir. Birçok çalışmada rüzgar hızı tahmin doğruluğunu artırmak için farklı istatistiksel yaklaşımlar araştırılmıştır.

Gilbert (1988) tarafından yapılan bir çalışmada rüzgar hızı tahmini için istatistiksel yöntemlerin kullanımı tartışılmıştır. Makalede, rüzgar hızı tahminine uygulanabilecek lognormal dağılım gibi asimetrik istatistiksel dağılımların kullanılmasından bahsedilmektedir. Makale, logaritmik veya karekök dönüşümleri kullanarak sağa çarpık dağılımların yaklaşık Gauss dağılımlarına dönüşümünü vurgulamaktadır. Bu yaklaşım, rüzgar hızı verilerini normalleştirmeye ve istatistiksel modellerin doğruluğunu artırmaya yardımcı olabilir.

Thorarinsdottir ve Gneiting (2009) tarafından yapılan bir başka çalışmada, rüzgar hızı için topluluk model çıktı istatistikleri (EMOS, Ensemble Model Output Statistic) adı verilen olasılıksal bir tahmin yöntemi tanıtılmıştır. Çalışma, değişken varyanslı sensör regresyonu (Tobit) kullanarak topluluk sistemlerindeki kalibrasyon ve sapma sorununu ele almaktadır. Bu yaklaşım, rüzgar hızı tahminleri için dinamik toplulukları sonradan işlemek için topluluktan türetilen konum ve yayılmayı içerir. EMOS yöntemi, Kuzey Amerika Pasifik Kuzeybatısı üzerindeki maksimum rüzgar hızının 48 saat ileriye dönük tahminlerine uygulanmış ve rüzgar hızı tahminlerinin doğruluğunu artırmadaki etkinliğini göstermiştir.

Kernel yoğunluk tahmininde, El-Dakkak ve ark. (2019) rüzgar hızı kernel yoğunluk tahmininde bant genişliği seçimi için kombinasyonel bir yöntem önermektedir. Bant genişliği seçimi, tahmin edilen yoğunluk fonksiyonunun düzgünlüğünü belirlediği için kernel yoğunluk tahmininde kritik bir adımdır. Çalışma, tahmin doğruluğunu optimize etmek için birden fazla

bant genişliğini birleştiren yeni bir yaklaşım sunmaktadır. Bu yöntem, kernel yoğunluk tahmin teknikleri kullanılarak rüzgar hızı tahmininin hassasiyetini artırabilir.

Sonuç olarak, istatistiksel yöntemler rüzgar hızı tahmininde önemli bir rol oynamaktadır. Lognormal dağılım gibi asimetrik istatistiksel dağılımların kullanılması, rüzgar hızı verilerinin normalleştirilmesine yardımcı olabilir. EMOS gibi olasılıksal tahmin yöntemleri, topluluk rüzgar hızı tahminlerinin kalibrasyonunu ve yanlılığını iyileştirebilir. Ek olarak, çekirdek yoğunluk tahmininde bant genişliği seçimi için kombinatoriyal yaklaşım, bu tekniği kullanarak rüzgar hızı tahmininin doğruluğunu artırabilir.

2.3.2. İstatistiksel Yöntemler

Gelecekteki rüzgar hızlarını tahmin etmek için otoregresif entegre hareketli ortalamalar (ARIMA, Autoregressive Integrated Moving Averages), üstel düzleştirme ve regresyon modelleri dahil olmak üzere çeşitli modeller kullanılabilir.

ARIMA modelleri rüzgar hızı tahmininde yaygın olarak kullanılmaktadır. Elsaraiti ve Merabet (2021) tarafından yapılan karşılaştırmalı bir analiz, ARIMA modelinin kısa vadeli rüzgar hızı tahmini için etkili olduğunu bulmuştur. Çalışma, gerçek zamanlı serileri ARIMA modelinin tahminleri ile karşılaştırmış ve en az hataya sahip modeli seçmiştir. Yazarlar, ARIMA modelinin kısa vadeli rüzgar hızı tahmini için uygun olduğu sonucuna varmışlardır.

ARIMA'ya ek olarak, Hussin ve ark. (2021) tarafından yapılan çalışmada, Malezya Yarımadası'nda gelecekteki rüzgar hızını tahmin etmek için ARIMA modeli uygulanmıştır. Yazarlar, 18 meteoroloji istasyonundan alınan rüzgar hızı verilerini kullanmış ve ARIMA modelinin üç istasyona iyi uyum sağladığını bulmuşlardır. Seri otokorelasyonu kontrol etmek için Ljung-Box testi ve artıklarda Otoregresif Koşullu Değişen Varyans (ARCH, Autoregressive Conditional Heteroscedasticity) etkisinin varlığını araştırmak için Engle'in Lagrange Çarpımı (LM, Lagrange Multiplier) testi kullanılmıştır. Yazarlar, kalan istasyonlar için günlük rüzgar hızı serisinin doğrusal olmayan özelliklerini yakalayan ARIMA-GARCH (Generalized AutoRegressive Conditional Heteroskedasticity, Genelleştirilmiş Oto Regresif Koşullu Değişen Varyans) modelini kullanmışlardır.

Üstel düzeltme, rüzgar hızı tahmini için kullanılabilecek bir başka yaklaşımdır. Ancak, verilen referansların hiçbiri rüzgar hızı tahmininde üstel düzeltme uygulamasını özel olarak tartışmamaktadır.

Regresyon modelleri de rüzgar hızı tahmini için kullanılabilir. Ancak, verilen referansların hiçbiri doğrudan regresyon modellerinin kullanımını ele almamaktadır.

Gelecekteki rüzgar hızlarını tahmin etmek için, otoregresif (AR, Auto-Regressive), otoregresif hareketli ortalama (ARMA, Auto Regressive Moving Average), otoregresif entegre hareketli ortalama (ARIMA, Auto-Regressive Integrated Moving Average), üstel düzleştirme ve regresyon modelleri dahil olmak üzere çeşitli modeller kullanılabilir.

Otoregresif (AR) model, gelecekteki değerleri tahmin etmek için tahmin edilen değişkenin geçmiş gözlemlerini kullanan bir zaman serisi modelidir. Değişkenin gelecekteki değerlerinin geçmişteki öneminin doğrusal bir kombinasyonu olduğunu varsayar. AR modeli jeoloji, biyoloji ve bilgisayar bilimleri gibi çeşitli alanlarda yaygın olarak kullanılmaktadır (Kendall, 1971). Otoregresif hareketli ortalama (ARMA) modeli, zaman serisi verilerindeki otoregresif ve hareketli ortalama modellerini yakalamak için otoregresif ve hareketli ortalama bileşenlerini birleştirir. Meteorolojide rüzgar hızı tahmini için kullanılmıştır (Kendall, 1971). Otoregresif entegre hareketli ortalama (ARIMA) modeli, zaman serisini durağan hale getirmek için farklılaştırmayı içeren ARMA modelinin bir uzantısıdır. Rüzgar hızı tahmininde yaygın olarak kullanılmaktadır (Kendall, 1971). ARIMA modeli kısa vadeli rüzgar hızını etkili bir şekilde tahmin eder (Kendall, 1971).

Üstel düzleştirme, geçmiş gözlemlere üstel olarak azalan ağırlıklar atayan bir zaman serisi tahmin yöntemidir. Jeoloji de dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır (Billah ve ark., 2006). Akaike'nin bilgi kriterine dayanan bilgi kriteri yaklaşımı, otomatik yöntem seçimi için iyi bir temel sağlar (Billah ve ark., 2006).

Regresyon modelleri rüzgar hızı tahmini için de kullanılabilir. Olasılıksal rüzgar hızı tahmini için homojen olmayan regresyon modelleri karşılaştırılmıştır (Lerch ve Thorarinsdottir, 2013). Çalışmaları olasıksal tahmine odaklansa da, regresyon modellerinin rüzgar hızı tahmininde uygulanabileceğini göstermektedir (Lerch ve Thorarinsdottir, 2013).

Sonuç olarak, AR, ARIMA, üstel düzleştirme ve regresyon modelleri rüzgar hızı tahmininde yaygın olarak kullanılmakta ve etkili olmaktadır. ARMA modeli de meteorolojide kullanılmıştır. ARIMA-GARCH modeli, rüzgar hızı serilerinin doğrusal olmayan özelliklerini yakalayabilir. Üstel düzleştirme ve regresyon modelleri verilen referanslarda açıkça tartışılmamıştır. Bu modeller, rüzgâr hızı verilerindeki örüntüleri ve eğilimleri yakalamak için farklı yaklaşımlar sağlar ve etkinlikleri belirli uygulama ve veri kümesine bağlı olarak değişebilir.

2.3.3. Makine Öğrenimi

Kısa vadeli rüzgar hızı tahmini, rüzgar türbini sahası fizibilitesinin değerlendirilmesinde çok önemlidir (Blanchard ve Samanta, 2019). Yapay sinir ağları (YSA), karmaşık doğrusal olmayan ilişkileri yakalama yetenekleri nedeniyle rüzgar hızı tahmini için yaygın olarak kullanılmaktadır (Blanchard ve Samanta, 2019).

Bir çalışmada, yenilenebilir enerji sistemlerinde rüzgar hızı tahmini için akıllı bir topluluk sinir ağı modeli önerilmiştir (Ranganayaki ve Deepa, 2016). Bu model, rüzgar hızını tahmin etmek için çok katmanlı algılayıcı, çok katmanlı uyarlanabilir doğrusal nöron (Madaline, Multilayer Adaptive Linear Neuron), geri yayımlı sinir ağı (BPN, Backpropagation Neural Network) ve olasılıksal sinir ağı (PNN, Probabilistic Neural Network) dahil olmak üzere birden fazla YSA modeli kullanmıştır. Bu modellerden tahmin edilen değerlerin ortalaması alınarak, akıllı topluluk sinir modeli minimum hata ile rüzgar hızı tahmininde daha iyi doğruluk elde etmiştir (Ranganayaki ve Deepa, 2016).

Başka bir çalışma, rüzgar hızı tahmini için bir YSA'daki en uygun gizli katman ve nöron sayısını belirlemeye odaklanmıştır (Rachmatullah ve ark., 2021). Yazarlar, YSA modelinin performansına dayalı olarak en uygun gizli katman ve nöron sayısını belirlemek için küme analizini kullanmıştır. Bu yaklaşım, gizli nöronların rastgele seçiminden kaynaklanan aşırı uyum veya yetersiz uyum sorunlarının önlenmesine yardımcı olur (Rachmatullah ve ark., 2021).

Ayrıca, bir çalışmada YSA'lar kullanılarak rüzgar hızı tahmini araştırılmış ve iki YSA çeşidi karşılaştırılmıştır: doğrusal olmayan otoregresif sinir ağları ve dışsal girdili doğrusal olmayan

otoregresif sinir ağıları (Blanchard ve Samanta, 2019). Yazarlar, Amerika Birleşik Devletleri'ndeki dört lokasyondan alınan bir yıllık saatlik hava durumu verilerini kullanarak bu ağıları eğitmiş, doğrulamış ve test etmiştir. Sonuçlar, rüzgar türbini saha değerlendirmesi için rüzgar hızını tahmin etmede YSA'ların etkinliğini göstermiştir (Blanchard ve Samanta, 2019).

Özetle, YSA'lar yenilenebilir enerji sistemleri için rüzgar hızı tahmininde başarıyla uygulanmıştır. Topluluk modellerinin kullanımı ve optimum gizli katmanların ve nöronların belirlenmesi, gelişmiş doğruluğa katkıda bulunur ve aşırı uyum veya yetersiz uyum sorunlarını önler. Bu yaklaşımlar, rüzgar türbini sahalarının fizibilitesini değerlendirmek için gerekli olan rüzgar hızı tahminlerinin güvenilirliğini artırmaktadır.

Kısa vadeli rüzgar hızı tahmini, rüzgar türbini saha değerlendirmesi ve yenilenebilir enerji sistemleri de dahil olmak üzere çeşitli uygulamalarda çok önemlidir. Yapay sinir ağıları (YSA), karmaşık doğrusal olmayan ilişkileri yakaladıkları için rüzgar hızı tahmininde yaygın olarak kullanılmaktadır (Luo ve ark., 2018).

Bir çalışmada, kısa vadeli rüzgar hızı tahmini için geliştirilmiş korelasyonlu yığılmış bir aşırı öğrenme makinesi (ELM, Extreme Learning Machine) modeli önerilmiştir (Luo ve ark., 2018). Bu model, rüzgar hızını tahmin etmek için girdi olarak önceki geçmiş verileri kullanmıştır. Yazarlar, modellerinin performansını otoregresif hareketli ortalamalar, destek vektör makinesi regresyonu ve YSA gibi geleneksel istatistiksel modellerle karşılaştırmıştır. Sonuçlar, yığılmış ELM modelinin bu geleneksel modellerden daha iyi performans gösterdiğini ortaya koymuş ve YSA'ların rüzgar hızı tahminindeki etkinliğini vurgulamıştır (Luo ve ark., 2018).

Başka bir çalışma, derin öğrenme kullanarak rüzgar hızı topluluk tahminine odaklanmıştır (İbrahim ve ark., 2021). Yazarlar, rüzgar hızı tahmini için yığılmış otomatik kodlayıcı (SAE, Stacked Auto-Encoder) ve yığılmış gürültü azaltıcı otomatik kodlayıcı (SDAE, Stacked Denoising Auto-Encoder) tabanlı bir derin sinir ağı (DNN, Deep Neural Network) mimarisi önermişlerdir. Otomatik kodlayıcının denetimsiz özellik öğrenme kabiliyeti, etiketsiz rüzgar verilerinden anlamlı özellikler çıkarmak için kullanılmıştır. Daha sonra rüzgar hızı tahmini için denetimli bir regresyon katmanı kullanılmıştır. Çalışma, DNN modelinin rüzgar hızı topluluğu tahminindeki etkinliğini göstermiştir (İbrahim ve ark., 2021).

Ayrıca, bir çalışmada rüzgar hızı tahmini için yapay sinir ağları, destek vektör regresyonu ve rastgele orman dahil olmak üzere makine öğrenimi algoritmalarının kullanımı araştırılmıştır (Brahimi, 2019). Yazarlar, geçmiş rüzgar hızı verilerini kullanarak bu algoritmaların performansını karşılaştırmıştır. Sonuçlar, yapay sinir ağının rüzgar hızı tahmininde en yüksek doğruluğu elde ettiğini göstermiş ve bu alandaki yapay zeka tabanlı tekniklerin potansiyelini daha da vurgulamıştır (Brahimi, 2019).

Ayrıca, İran'ın Tahran kentinde yapılan bir çalışmada, YSA'lar kullanılarak kısa vadeli rüzgar hızı tahmini araştırılmıştır (Fazelpour ve ark., 2016). Yazarlar, YSA modellerinin performansını otoregresif entegre hareketli ortalama ve destek vektör regresyonu dahil olmak üzere diğer yöntemlerle karşılaştırmıştır. Sonuçlar, parçacık sürüşü optimizasyonu hibridizasyonuna sahip YSA modelinin en düşük kök ortalama kare hata ve ortalama kare hata değerlerini elde ettiğini ve rüzgar hızı tahmininde üstün performans gösterdiğini ortaya koymuştur (Fazelpour ve ark., 2016).

Özetle, YSA'lar kısa vadeli rüzgar hızı tahmininde başarıyla uygulanmıştır. Yığılmış ELM modellerinin kullanılması, otomatik kodlayıcılarla derin öğrenme mimarileri ve optimizasyon algoritmalarıyla hibridizasyon, doğruluğun artmasına ve geleneksel istatistiksel modellerden daha iyi performans göstermesine katkıda bulunur. Bu yaklaşımlar, rüzgar enerjisi sistemlerindeki çeşitli uygulamalar için çok önemli olan rüzgar hızı tahminlerinin güvenilirliğini artırmaktadır.

Sağlanan referanslara dayanarak, burada rüzgar hızı tahmininde topluluk yaklaşımlarının bir sentezi bulunmaktadır:

Topluluk yöntemleri, tek modellere kıyasla tahmin performansını artırmak için rüzgar hızı tahmininde yaygın olarak kullanılmaktadır. Bu yöntemler, daha doğru ve güvenilir bir tahmin oluşturmak için birden fazla modelin tahminlerini birleştirir. Yaygın bir yaklaşım, aynı modeli farklı konfigürasyonlarla çalıştırarak veya başka modelleri birlikte kullanarak bir topluluk oluşturmaktır (Deppe ve ark., 2013).

Rüzgar hızı tahmininde, topluluk yöntemleri çeşitli teknikler kullanılarak uygulanmıştır. Örneğin, Hava Araştırma ve Tahmin Modeli (WRF, Weather Research and Forecasting), farklı gezegensel sınır tabaka (PBL, Planetary Boundary Layer) şemaları ile simülasyonlar

çalıştırarak bir topluluk oluşturmak için kullanılmıştır (Deppe ve ark., 2013). Bu durumda topluluk üyeleri rüzgar hızı tahminlerinde çok az yayılma göstermiş ve bu da gelişmiş doğruluk potansiyeline işaret etmiştir.

Derin öğrenme teknikleri de rüzgar hızı topluluk tahmininde kullanılmıştır. Bir çalışma, rüzgar hızı tahmini için yığılmış otomatik kodlayıcılara ve gürültü azaltıcı otomatik kodlayıcılara dayalı bir derin sinir ağı (DNN) mimarisi önermiştir (İbrahim ve ark., 2021). Bu otomatik kodlayıcıların denetimsiz özellik öğrenme kabiliyeti, etiketsiz rüzgar verilerinden anlamlı özellikler çıkarmak için kullanılmış ve bu da topluluk tahminlerinin iyileştirilmesine yol açmıştır.

Model tabanlı topluluk yaklaşımlarına ek olarak, olasılıksal rüzgar hızı tahminleri oluşturmak için istatistiksel yöntemler kullanılmıştır. Örneğin, bir sayısal hava tahmini (NWP) modelinin çıktısı, yerel olarak kalibre edilmiş, olasılıksal rüzgar hızı tahminleri sağlamak için topluluk model çıktı istatistikleri (EMOS, Community Model Output Statistics) kullanılarak sonradan işlenebilir (Scheuerer ve Möller, 2015). Bu yaklaşım, bir topluluk tahmin sisteminin tahminlerini dikkate alır ve gelecekteki rüzgar hızı gözlemleri hakkında olasılıksal tahminler yapmak için istatistiksel dağılımları kullanır.

Ayrıca, rüzgar hızı tahminini geliştirmek için topluluk yöntemleri diğer tekniklerle birleştirilmiştir. Örneğin, veri ön işleme, geliştirilmiş bir çok amaçlı optimizasyon algoritması, hata düzeltme ve doğrusal olmayan bir topluluk stratejisini entegre eden iki aşamalı bir tahmin sistemi önerilmiştir (Zhang ve ark., 2019). Bu yaklaşım, hata bilgisini kullanmayı, her bir bileşenin tahmin değerini entegre etmeyi ve tahmin istikrarını iyileştirmeyi amaçlamıştır.

Genel olarak, rüzgar hızı tahmininde topluluk yaklaşımları doğruluk ve güvenilirliği artırma konusunda umut vaat etmektedir. Bu yöntemler, birden fazla modelin veya konfigürasyonun tahminlerini birleştirerek daha sağlam tahminler sağlayabilir ve rüzgar hızı tahminiyle ilişkili belirsizlikleri daha iyi yakalayabilir.

Rüzgar hızı tahminine yönelik hibrit yaklaşımlar, tahmin doğruluğunu artırmak için birden fazla tekniğin veya modelin birleştirilmesini içerir. Burada rüzgar hızı tahmininde hibrit yaklaşımlarla ilgili potansiyel referansların bir sentezi yer almaktadır:

Yang ve ark. (2017) tarafından yapılan çalışma, 'ayırıştırma ve topluluk' stratejisi ile bulanık zaman serisi tahmin algoritmasını birleştiren hibrit bir tahmin sistemi önermektedir. Yöntem iki modülden oluşmaktadır: veri ön işleme ve tahmin. Yazarlar önerilen hibrit sistemi istatistiksel, yapay sinir ağları ve destek vektör regresyon modelleri ile karşılaştırmaktadır. Sonuçlar, hibrit sistemin özellikle gürültü ve kararsızlıktan etkilenen rüzgar hızı verileri için tahmin doğruluğunu ve kararlılığını önemli ölçüde artırdığını göstermektedir.

Eide ve ark. (2017), yayınladıkları makalede, rüzgar hızı ve yönü için NWP tahminleri topluluğuna dayalı olasılıksal rüzgar hızı tahminleri oluşturmaya odaklanmaktadır. Yazarlar, diğer NWP değişkenlerini ve tahmin edilen değişkeni içeren bir Bayesian model ortalaması yaklaşımı önermektedir. Çalışma, güvenilirliği ve beceriyi artırmak için topluluk tahminlerine ek değişkenler dahil etme potansiyelini vurgulamaktadır.

Ma ve ark. (2020) yaptıkları çalışmada, kısa vadeli rüzgar hızı tahmini için meta-öğrenme tabanlı bir hibrit topluluk yaklaşımı sunmaktadır. Önerilen yaklaşım, bir meta öğrenme çerçevesi kullanarak otoregresif entegre hareketli ortalamalar (ARIMA), uzun kısa süreli bellek (LSTM, Long Short-Term Memory) ve destek vektör regresyonu (SVR, Support Vector Regression) dahil olmak üzere birden fazla tahmin modelini birleştirmektedir. Sonuçlar, hibrit topluluk yaklaşımının bireysel modellerden daha iyi performans gösterdiğini ve rüzgar hızı tahmininde daha yüksek doğruluk elde ettiğini göstermektedir.

Nguyen ve Phan (2022) yayınladıkları çalışmada, saatlik gün öncesi rüzgar hızı tahmini için hibrit bir model önermektedir. Model, topluluk ampirik mod ayrıştırması (EEMD, Ensemble Empirical Mode Decomposition), evrimsel sinir ağı (CNN, Convolutional Neural Network), çift yönlü uzun kısa süreli bellek (Bi-LSTM, Bidirectional Long Short Term Memory) ve genetik algoritma (GA, Genetic Algorithm) optimizasyonunu birleştirmektedir. Sonuçlar, hibrit modelin karşılaştırılan diğer rüzgar hızı tahmin yöntemlerinden daha iyi performans gösterdiğini ve rüzgar hızı tahmininde etkinliğini ortaya koyduğunu göstermektedir.

Bu referanslar, ayırıştırma ve topluluk stratejileri, bulanık zaman serileri, Bayesian model ortalaması, meta öğrenme ve optimizasyon algoritmaları gibi farklı teknikleri birleştiren rüzgar hızı tahminindeki hibrit yaklaşımları vurgulamaktadır. Bu hibrit modeller, bireysel modellere

veya geleneksel yöntemlere kıyasla rüzgar hızı tahmininde gelişmiş doğruluk ve kararlılık göstermektedir.

Rüzgar hızı tahmini, rüzgar enerjisi planlaması ve yönetiminin önemli bir yönüdür. Rüzgar türbinlerinin performansını optimize etmek ve enerji üretimini en üst düzeye çıkarmak için rüzgar hızının doğru tahminleri çok önemlidir. Rüzgar hızı tahmini için ampirik mod ayrıştırma (EMD, Empirical Mode Decomposition) tabanlı yöntemler, destek vektör regresyonu (SVR) ve yapay sinir ağları (YSA) dahil olmak üzere çeşitli yöntemler önerilmiştir (Ren ve ark., 2015).

Bir çalışmada, kısa vadeli rüzgar hızı tahmini için SVR ve YSA dahil olmak üzere farklı EMD tabanlı hibrit tahmin yöntemleri karşılaştırılmıştır. Sonuçlar, EMD tabanlı hibrit yöntemlerin rüzgar hızı tahmininde iyi performans gösterdiğini ortaya koymuştur (Ren ve ark., 2015).

Başka bir çalışma, rüzgar hızı tahmini de dahil olmak üzere rüzgar enerjisinde SVR'nin geniş uygulama alanını vurgulamıştır. SVR, çalışma eğrisi analizi, rüzgar çiftliği yerleşim optimizasyonu ve rüzgar hızı tahmini gibi rüzgar enerjisiyle ilgili çeşitli problemler için kullanılmıştır (Castellani ve ark., 2021).

Saatlik rüzgar hızı ve rüzgar gücü tahmini için SVR dahil olmak üzere farklı tahmin modellerinin karşılaştırıldığı bir çalışmada, SVR'nin doğruluk açısından iyi performans gösterdiği bulunmuştur. Çalışma, modelleri değerlendirmek için çapraz doğrulama kullanmış ve SVR'nin rüzgar hızı tahmini için güvenilir bir yöntem olduğu sonucuna varmıştır (Adnan ve ark., 2019).

Ayrıca, bir çalışmada parçacık sürüsü optimizasyonu (PSO) ile SVR'ye dayalı bir rüzgar hızı tahmin modeli önerilmiştir. Model, YSA ve otoregresif entegre hareketli ortalama (ARIMA) dahil olmak üzere diğer tahmin modelleriyle karşılaştırılmış ve sonuçlar, SVR-PSO modelinin doğruluk açısından diğer modellerden daha iyi performans gösterdiğini göstermiştir. Çalışma, SVR-PSO modelinin rüzgar hızı tahmini için umut verici bir yaklaşım olduğu sonucuna varmıştır (Wang ve ark., 2020).

Genel olarak, SVR yaygın olarak kullanılmış ve rüzgar hızı tahmininde etkili olduğu kanıtlanmıştır. Rüzgâr enerjisi ile ilgili çeşitli uygulamalarda kullanılmış ve diğer tahmin

modellerine kıyasla iyi performans göstermiştir. SVR'nin PSO gibi optimizasyon algoritmalarıyla kombinasyonu, rüzgar hızı tahminindeki doğruluğunu daha da artırır.

Rastgele ormanlar, rüzgar enerjisi alanında rüzgar hızı tahmini için yaygın olarak kullanılmaktadır. Bir çalışmada, rüzgâr hızına bağlı olarak rüzgâr türbini gürültüsünü tahmin etmek için rastgele orman regresyonu uygulanmıştır (Iannace ve ark., 2019). Model, Pearson korelasyon katsayısının (0,981) yüksek bir değerine ulaşarak doğru tahminleri göstermiştir (Iannace ve ark., 2019). Bu, rüzgar hızı tahmini için rastgele orman regresyonunun potansiyelini göstermektedir.

Başka bir çalışma, denetimli bir tahmin modeli olarak rastgele ormanı kullanan kısa vadeli bir rüzgar hızı tahmin modeli önermiştir (Huang ve ark., 2019). Model, rastgele orman algoritmasını optimize etmek için veri odaklı bir boyut azaltma prosedürü ve ağırlıklı bir oylama yöntemi içermektedir (Huang ve ark., 2019). Bu yaklaşım, düşük bilgi kaybı ile doğru rüzgar hızı tahminleri ile sonuçlanmıştır (Huang ve ark., 2019).

Buna ek olarak, bir çalışma ultra kısa vadeli rüzgar gücü tahminine odaklanmış ve bir ELM modelini optimize etmek için salp sürüsü algoritmasını kullanmıştır (Tan ve ark., 2020). Bu çalışma özellikle rüzgar enerjisi tahminini ele alsa da, ELM ve optimizasyon algoritmalarının kullanımı, rüzgar hızı tahmini için rastgele ormanları diğer tekniklerle birleştirme potansiyelini vurgulamaktadır (Tan ve ark., 2020).

Bu çalışmalar toplu olarak rastgele ormanların rüzgar hızı tahminindeki etkinliğini göstermektedir. Rastgele orman algoritması, rüzgar enerjisi planlaması ve yönetimindeki çeşitli uygulamalar için çok önemli olan rüzgar hızını doğru bir şekilde tahmin etmede umut vaat ettiğini göstermiştir.

Gradyan artırma regresyonu, rüzgar enerjisi alanında rüzgar hızı tahmini için yaygın olarak kullanılmaktadır. Bir çalışma, gradyan artırma makineleri hakkında kapsamlı bir eğitim sunmuş, teorik yönlerini ve uygulamasının pratik örneklerini tartışmıştır (Natekin ve Knoll, 2013). Eğitim, gradyan artırma modeli tasarımının tüm aşamalarını kapsamakta ve model karmaşıklığının ele alınmasına ilişkin içgörüler sağlamaktadır. Çalışma ayrıca rüzgâr hızı

tahmini için deęerli olabilecek üç pratik gradyan artırma uygulaması örneęi sunmaktadır (Natekin ve Knoll, 2013).

Başka bir çalışma, tahmin sürecinde kategorik özelliklerin ele alınmasındaki zorlukları özellikle ele alan bir gradyan artırma çerçevesi olan CatBoost'u tanıtmıştır (Prokhorenkova ve ark., 2017). CatBoost, karar ağaçları üzerinde gradyan artırmaya dayalı bir makine öğrenimi yöntemidir. Bu çalışma kategorik değişkenlere odaklansa da, gradyan artırmanın çeşitli veri türlerini işlemedeki etkinliğini vurgulamaktadır ve genellikle hem sayısal hem de kategorik değişkenleri içeren rüzgar hızı tahmini için uygun olabilir (Prokhorenkova ve ark., 2017).

Bu referanslar, rüzgar hızı tahmini için gradyan artırma regresyonunun potansiyelini ve etkinliğini toplu olarak göstermektedir. Gradyan artırma teknikleri, rüzgar enerjisi de dahil olmak üzere çeşitli alanlarda yaygın olarak uygulanmış ve rüzgar hızını doğru bir şekilde tahmin etmede umut verici sonuçlar göstermiştir. Kapsamlı eğitim ve CatBoost gibi özel çerçevelerin geliştirilmesi, rüzgar hızı tahmini için gradyan artırmanın yeteneklerini daha da geliştirmektedir.

2.3.4. Topluluk Yöntemleri

Katılımcı rüzgar hızı tahmini olarak da bilinen topluluk tabanlı rüzgar hızı tahmini, rüzgar hızlarını tahmin etmek için bir topluluktaki bireylerin kolektif bilgi ve gözlemlerinden yararlanmayı içerir. Bu yaklaşım, geleneksel rüzgar hızı ölçüm altyapısının sınırlı veya erişilemez olduğu alanlarda deęerli olabilir.

Bir çalışma, rüzgâr hızı tahmini için kitle kaynaklı kentsel rüzgâr verilerinin potansiyelini ve uygulamasını değerlendirmiştir (Droste ve ark., 2020). Çalışma, kentsel alanlardaki rüzgar hızlarını tahmin etmek için kişisel meteoroloji istasyonlarından (PWS, Personal Weather Stations) gelen verileri kullanmaya odaklanmıştır. Sonuçlar, PWS anemetrelerinin sıfıra yakın rüzgar hızlarını ölçmede sınırlamaları olmasına rağmen, genel rüzgar hızı klimatolojisi tahmininin tatmin edici olduğunu göstermiştir. Bu durum, kentsel ortamlarda rüzgâr hızı tahmini için kitle kaynaklı verilerin kullanılma potansiyelini vurgulamaktadır (Droste ve ark., 2020).

Katılımcı rüzgar hızı tahminine özel olarak odaklanmamış olsa da, başka bir çalışma, olasılık ön bilgisini içeren rüzgar hızı tahmini için bir SVR yöntemi önermiştir (Chen ve ark., 2014). Çalışma, önerilen yöntemin bir rüzgar çiftliğindeki rüzgar hızlarını tahmin etmedeki fizibilitesini ve etkinliğini göstermiştir. Bu durum, SVR veya benzer makine öğrenimi tekniklerinin, topluluk gözlemlerini modele girdi olarak dahil ederek katılımcı rüzgar hızı tahmininde uygulanabileceğini göstermektedir (Chen ve ark., 2014).

Özetle, özellikle katılımcı rüzgar hızı tahminini ele alan sınırlı araştırma olmasına rağmen, kitle kaynaklı verilerin ve SVR gibi makine öğrenimi tekniklerinin potansiyeli, topluluk tabanlı rüzgar hızı tahmininin umut verici bir yaklaşım olduğunu göstermektedir. Bir topluluk içindeki bireylerin kolektif gözlemlerinden yararlanarak, geleneksel ölçüm altyapısının eksik olabileceği alanlarda rüzgar hızlarını tahmin etmek mümkündür.

Topluluk tabanlı rüzgar hızı tahmini, bir topluluk içindeki çok sayıda bireyden rüzgar hızı verilerini toplamak için kitle kaynak kullanımının gücünden yararlanmayı içerir. Bu yaklaşım, sağlık araştırmaları Ranard ve ark. (2013) ve meteoroloji (Chen ve ark., 2021) dahil olmak üzere çeşitli alanlarda dikkat çekmiştir.

Rüzgar hızı tahmini bağlamında, kitle kaynak kullanımı resmi ölçümleri tamamlayan değerli veriler sağlayabilir. Chen ve arkadaşları (2021) kitle kaynaklı rüzgâr hızı gözlemlerinin kalite kontrolü ve yanlışlık düzeltilmesi üzerine bir çalışma yürütmüştür. Elde ettikleri sonuçlar, kalite kontrol kontrolleri ve yanlışlık ayarlama adımları uygulandıktan sonra kitle kaynaklı rüzgar hızı verilerinin resmi verilerle daha karşılaştırılabilir hale geldiğini göstermiştir. Bu durum, kitle kaynaklı rüzgar hızı gözlemlerinin ek rüzgar gözlemleri gerektiren uygulamalar için değerli bir kaynak olma potansiyelini göstermektedir.

Chen ve ark. (2021) tarafından yapılan çalışmanın odak noktası kitle kaynaklı rüzgar hızı verilerinin kalite kontrolü ve yanlışlık ayarlaması olsa da, topluluk tabanlı rüzgar hızı tahmini potansiyeli hakkında fikir vermektedir. Kitle kaynaklı verilerin güvenilirliğini ve doğruluğunu sağlayarak, rüzgar hızını etkili bir şekilde tahmin etmek için topluluğun kolektif gücünden yararlanmak mümkün hale gelir.

Kitle kaynak kullanımına ek olarak, sinir ağıları ve genişletilmiş Kalman filtreleri gibi diğer yöntemler de rüzgar hızı tahmini için araştırılmıştır. Hur (2019), sinir ağıları ve genişletilmiş Kalman filtreleri kullanarak rüzgâr türbinleri ve çiftliklerindeki faydalı değişkenleri tahmin etmek için bir yaklaşım önermiştir. Bu çalışmanın odak noktası özellikle topluluk tabanlı rüzgar hızı tahmini olmasa da, rüzgar enerjisi sistemlerinde doğru rüzgar hızı tahmini için veri güdümlü modellerin potansiyelini vurgulamaktadır.

Sonuç olarak, kitle kaynak kullanımı yoluyla topluluk tabanlı rüzgar hızı tahmini, rüzgar enerjisi sistemleri için değerli veriler sağlama potansiyeline sahiptir. Kalite kontrol kontrolleri ve yanlılık düzeltme adımları uygulanarak, kitle kaynaklı rüzgar hızı gözlemleri resmi verilerle karşılaştırılabilir hale getirilebilir. Bu yaklaşım, sinir ağıları gibi veri odaklı modellerle birleştirildiğinde, daha doğru ve güvenilir rüzgar hızı tahminine katkıda bulunabilir ve sonuçta rüzgar enerjisi sistemlerinin verimliliğini ve istikrarını artırabilir.

2.3.5. Hibrit Yaklaşımlar

Rüzgar hızı tahmini, rüzgar çiftliklerinin ve güç sistemlerinin verimli çalışması ve planlanması için çok önemli bir görevdir. Kısa vadeli rüzgar hızı tahmininin doğruluğunu artırmak için araştırmacılar, farklı yöntemleri ve algoritmaları birleştiren çeşitli hibrit tahmin teknikleri önermişlerdir.

Bu tür hibrit tekniklerden biri (Kang ve ark., 2017) tarafından önerilen EEMD-LSSVM modelidir. Bu model, orijinal rüzgar hızı zaman serisini alt serilere ayırmak için Topluluk Ampirik Mod Ayırıştırma (EEMD, Ensemble Empirical Mode Decomposition) kullanır ve ardından bu alt serileri tahmin etmek için En Küçük Kareler Destek Vektör Makinesi (LSSVM, Least Square Support Vector Machine) uygular. EEMD ve LSSVM kombinasyonu, kısa vadeli rüzgar hızı tahmininin hassasiyetini artırır.

Bir başka hibrit yaklaşım ise dalgacık dönüşümüne (WT, Wavelet Transform) dayalı bir veri filtreleme tekniğini bulanık ARTMAP (FA, Fuzzy ARTMA) ağına dayalı bir yumuşak hesaplama modeliyle birleştiren yapıdır ve Haque ve ark. (2013) tarafından sunulmuştur. Hibrit WT + FA modeli, diğer mevcut rüzgar hızı tahmin yöntemlerine kıyasla gelişmiş tahmin doğruluğu göstermektedir.

Tatinati ve Veluvolu (2013), rüzgar hızı tahmini için ampirik mod ayrıştırma (EMD) ile uyarlanabilir yöntemleri birleştiren hibrit bir yöntem önermektedir. Rüzgâr hızı verileri önce EMD kullanılarak içsel mod fonksiyonlarına (IMF, Intrinsic Mode Functions) ayrıştırılır ve daha sonra kısmi otokorelasyon faktörlerine dayalı olarak IMF'leri tahmin etmek için uyarlamalı yöntemler kullanılır.

Buna ek olarak, Xu ve Yang (2020) kısa vadeli rüzgar hızı tahmini için EMD ve Çoklu Çekirdek Öğrenme (MKL, Multiple Kernel Learning) tabanlı hibrit bir model önermektedir. Bu model, MKL kullanarak birden fazla tahmin fonksiyonuna uyarlanabilir şekilde ağırlıklar atar ve bu da oldukça karmaşık sinyaller için rüzgar hızı tahmininin doğruluğunu artırır.

Ayrıca, Zhao ve ark. (2020) kısa vadeli rüzgar hızı tahmini için Gauss süreci (GP, Gaussian Process) ve uyarlanmamış Kalman filtresini (UKF, Unscented Kalman Filter) birleştiren hibrit bir doğrusal olmayan tahmin yaklaşımı önermektedir. Bu yaklaşım, rüzgar hızının dinamik değişimlerini yakalamayı ve tahmin doğruluğunu artırmayı amaçlamaktadır.

Bu hibrit tahmin teknikleri, rüzgar hızı tahmininin doğruluğunu artırma potansiyelini göstermektedir. Farklı yöntem ve algoritmaları bir araya getiren bu yaklaşımlar, tahmin hassasiyetini artırmak için her bir bileşenin güçlü yönlerinden yararlanmaktadır. EEMD, dalgacık dönüşümü, ampirik mod ayrıştırma ve çoklu çekirdek öğrenme gibi tekniklerin kullanımı, rüzgar hızı verilerinin doğrusal olmayan ve durağan olmayan doğasının etkili bir şekilde ele alınmasını sağlar.

2.4. Veri Ayrıştırması

Veri ayrıştırma, sinyal işleme, biyoloji ve çevre bilimi de dahil olmak üzere çeşitli alanlarda temel bir kavramdır. Karmaşık veri setlerini daha küçük, daha yönetilebilir bileşenlere ayırmayı içerir ve daha kolay analiz ve yorumlamayı kolaylaştırır (Cusack ve ark., 2009; Cichocki ve ark., 2015).

Sinyal işleme alanında, tensör ayrıştırmaları gibi veri ayrıştırma tekniklerinin oldukça değerli olduğu kanıtlanmıştır. Tensör ayrıştırmaları, geleneksel korelasyon ve alt uzay teknikleri, sinyal ayrıştırma, doğrusal regresyon, özellik çıkarma ve sınıflandırma gibi yaygın olarak kullanılan

sinyal işleme paradigmalarının genelleştirilmesini sağlar (Cichocki ve ark., 2015). Bu teknikler, verilerin altında yatan yapı ve ilişkilerin kapsamlı bir şekilde anlaşılmasını sağlayarak daha doğru ve verimli analizlere yol açmaktadır.

Biyoloji ve çevre bilimi bağlamında, veri ayrıştırma, çöp ayrışma oranları gibi süreçlerin anlaşılmasında çok önemli bir rol oynar. Çalışmalar, karasal ekosistemlerde önemli bir karbon akışını temsil eden çöp ayrışmasının, iklim ve çöp kalitesi de dahil olmak üzere çeşitli faktörlerden etkilendiğini göstermiştir (Cusack ve ark., 2009). Araştırmacılar, verileri ayrıştırarak ve bu faktörlerin göreceli önemini analiz ederek, çöp ayrışma oranları üzerindeki kontroller hakkında bilgi edinebilir ve ekosistem dinamikleri hakkında tahminlerde bulunabilirler.

Veri ayrıştırma teknikleri kimyada karmaşık kimyasal sistemleri analiz etmek ve davranışlarını anlamak için kullanılır. Örneğin, karma kütle spektrometresinde veri ayrıştırma yöntemleri, karmaşık karışımlardan tek tek kütle spektrumlarını ayırmak ve tanımlamak için kullanılır (Mohammed ve ark., 2012). Araştırmacılar, verileri ayrıştırarak tek tek bileşenleri izole ve analiz edebilir, böylece belirli bileşiklerin ve özelliklerinin tanımlanmasını sağlayabilir.

Veri ayrıştırma, biyoinformatik ve genomik alanlarındaki büyük ölçekli biyolojik veri kümelerinin analizinde önemli bir rol oynamaktadır. Temel bileşen analizi (PCA, Principal Component Analysis) ve bağımsız bileşen analizi (ICA, Independent Component Analysis) gibi teknikler, gen ifadesi verilerinin analizinde veri ayrıştırma için yaygın olarak kullanılmaktadır (Mohammed ve ark., 2012). Bu teknikler, araştırmacıların örüntüleri tanımlamasına ve verilerden anlamlı özellikler çıkarmasına olanak tanıyarak gen işlevi, hastalık mekanizmaları ve potansiyel iyileştirici hedefler hakkında iç görüler elde edilmesini sağlar.

Ayrıca, veri ayrıştırma konteyner iş hacmi tahmini alanında da önemlidir. COVID-19 salgını bağlamında, aşırı olayların liman operasyonları üzerindeki etkisini analiz etmek için iteratif kümülatif kareler toplamı (ISCC, Iterative Cumulative Sum of Squares) gibi veri ayrıştırma teknikleri kullanılmıştır (Huang ve ark., 2022). Araştırmacılar, verileri farklı özelliklere ayrıştırarak, salgın olayın liman performansının her bir yönü üzerindeki spesifik etkilerini değerlendirebilir ve böylece daha doğru tahmin ve karar alma süreçlerine olanak sağlayabilir.

Genel olarak, veri ayrıştırma, karmaşık veri setlerinin analiz edilmesini ve yorumlanmasını sağladığı için çeşitli alanlarda büyük önem taşımaktadır. Araştırmacılar, verileri daha küçük bileşenlere ayırarak, verilerin altında yatan yapı ve ilişkiler hakkında daha derin bir anlayış kazanabilir, bu da daha doğru tahminler, verimli analizler ve bilinçli karar verme süreçleri sağlar.

Veri ayrıştırma tekniklerinin rüzgar hızı tahmini ve tahmininde önemli olduğu kanıtlanmıştır. Qu ve ark. (2016) ile Ali ve ark. (2017), bu bağlamda veri ayrıştırmanın önemini vurgulamaktadır.

Ali ve ark. (2017), varyasyonel mod ayrıştırmasına (VMD, Variational Mode Decomposition) dayalı hibrit çok ölçekli bir rüzgar hızı tahmin yöntemi önermektedir. VMD, ampirik mod ayrıştırması gibi diğer yöntemlere kıyasla gelişmiş doğruluk sunan, veriye uyarlanabilir bir sinyal ayrıştırma tekniğidir. Yazarlar, rüzgar hızı verilerini çoklu içsel dar bant bileşenlerine ayırmak için VMD'yi kullanmaktadır, bu da rüzgar hızının tahminini ve öngörüsünü kolaylaştırmaktadır. Önerilen yöntemin etkinliği, Pakistan'daki birden fazla sahadan elde edilen büyük bir rüzgar hızı veri kümesi üzerinde yapılan kapsamlı deneylerle gösterilmiştir (Ali ve ark., 2017).

Benzer şekilde, Qu ve ark. (2016) rüzgâr hızı tahmini için EEMD meyve sineği optimizasyon algoritması ile birleştiren hibrit bir model sunmuştur. EEMD, rüzgar hızı serileri gibi doğrusal olmayan ve karmaşık sinyal dizilerini ayırmak için gelişmiş ve etkili bir teknolojidir. Yazarlar, etkili bir tahmin modeli oluşturmak için orijinal rüzgar hızı veri setlerinin özelliklerini kapsamlı bir şekilde analiz etmenin ve dikkate almanın önemini vurgulamaktadır. EEMD, ampirik mod ayrıştırmasının eksikliklerini gidermekte ve dalgacık ayrıştırması ve Fourier ayrıştırması gibi diğer ayrıştırma yaklaşımlarına göre avantajlar sunmaktadır (Qu ve ark., 2016).

Her iki referans da VMD ve EEMD gibi veri ayrıştırma tekniklerinin rüzgar hızı tahmini ve öngörüsündeki önemini vurgulamaktadır. Bu teknikler, rüzgar hızı verilerinin içsel bileşenlere ayrıştırılmasını sağlayarak rüzgar hızı davranışının daha doğru analiz edilmesine ve tahmin edilmesine olanak tanır. Araştırmacılar verileri ayrıştırarak, rüzgar hızı değişimlerine katkıda

bulunan kalıpları, eğilimleri ve altta yatan yapıları belirleyebilir ve sonuçta rüzgar hızı tahmini ve tahmin modellerinin doğruluğunu artırabilir.

2.5. Dalgacık sinir ağları

Dalgacık sinir ağları (WNN, Wavelet Neural Network), geleneksel sigmoid aktivasyon fonksiyonu yerine aktivasyon fonksiyonu olarak dalgacıkları kullanan bir sinir ağı türüdür (Wang ve ark., 2013). WNN'ler çeşitli uygulamalarda başarılı bir şekilde uygulanmıştır, ancak uygulamaları için genel bir çerçeve eksikliği vardır (Alexandridis ve Zapraniş, 2013). Son çalışmalarda, araştırmacılar WNN'lerin tıp ve biyoloji gibi farklı alanlarda kullanımını araştırmışlardır.

Bir çalışma, veri artırımı ile yeni bir derin öğrenme yaklaşımı kullanarak motor görüntü sinyallerini sınıflandırmaya odaklanmıştır (Zhiwen ve ark., 2019). Araştırmacılar, eğitim sürecini iyileştirmek için geleneksel sinir ağlarındaki konvolüsyonel katmanları dalgacıklarla değiştirmiştir. Deneyisel sonuçlar, dalgacık sinir ağının mevcut yaklaşımlardan daha yüksek sınıflandırma doğrulukları elde ettiğini göstermiştir. Araştırmacılar ayrıca dalgacık sinir ağının performansını kararlı durum görsel uyarılmış potansiyellerin sınıflandırılmasında da test etmişlerdir.

Bir başka çalışmada, hedef tehdit değerlendirme için bir sinir ağında çoklu dalgacık fonksiyonlarının kullanılması araştırılmıştır (Wang ve ark., 2013). Dalgacık sinir ağı, sinir ağlarının ve dalgacık dönüşümlerinin avantajlarını birleştirir. Aktivasyon fonksiyonu olarak birden fazla dalgacık fonksiyonu kullanarak, ağ farklı girdi veri özelliklerini yakalayabilir ve hedef tehdit değerlendirmesindeki performansını artırabilir.

Ekonomi alanında araştırmacılar, Dow Jones Borsası Endüstri Endeksi (DJIA, Dow Jones Industrial Average) endeksi tahmini için otoregresif kesirli entegre hareketli ortalamaları (ARFIMA, Autoregressive Fractionally Integrated Moving Averages) ve dalgacık sinir ağlarını birleştiren hibrit bir model önermişlerdir (Boubaker ve ark., 2022). Dalgacık sinir ağı, regresyon doğruluğu ve hata tolerans kabiliyeti açısından avantajlar göstermiştir. Hibrit model, ARFIMA modelini dahil ederek uzun vadeli bağımlılıkları yakalayabilir ve tahmin doğruluğunu artırabilir.

Genel olarak, dalgacık sinir ağıları çeşitli alanlarda ve uygulamalarda umut vaat etmektedir. Aktivasyon fonksiyonu olarak dalgacıkları kullanarak geleneksel sinir ağlarına farklı bir yaklaşım sunmaktadırlar. Dalgacıkların kullanımı, ağıın farklı girdi veri özelliklerini yakalamasına ve performansını artırmasına olanak tanır. Bununla birlikte, dalgacık sinir ağlarını uygulamak için genel bir çerçeve geliştirmek ve diğer alanlardaki potansiyellerini keşfetmek için daha fazla araştırmaya ihtiyaç vardır.

Rüzgar hızı zaman serisi verilerinin farklı frekans bileşenlerini çıkarmak için çalışma, rüzgar hızı tahmini için ayırık dalgacık dönüşümü (DWT, Discrete Wavelet Transform) ve YSA birleştiren hibrit bir model önermektedir (Berrezzek ve ark., 2019). Rüzgâr hızı tahmini için WNN'leri doğrudan uygulayan spesifik çalışmalar olmamasına rağmen, rüzgâr hızı tahmin doğruluğunu artırmak için dalgacık ayrıştırma veya dalgacık paket ayrıştırma teknikleriyle birlikte uzun kısa süreli bellek (LSTM) ve evrişimli sinir ağları (CNN'ler) gibi diğer sinir ağı mimarilerini kullanan ilgili çalışmalar vardır (Fukuoka ve ark., 2018; Zhang ve ark., 2020).

Fukuoka ve ark. (2018), LSTM ve 1D-CNN (One-dimensional Convolutional Neural Network, Tek Boyutlu Evrişimsel Sinir Ağı) kullanarak bir rüzgar hızı tahmin modeli sunmuştur. Model, LSTM kullanarak rüzgar hızının geçmiş bilgilerini dikkate almakta ve verilerdeki mekansal bağımlılıkları yakalamak için tek boyutlu bir CNN içermektedir. Bu çalışma doğrudan bir dalgacık sinir ağı kullanmasa da, rüzgar hızı tahmini için farklı sinir ağı mimarilerini birleştirmenin etkinliğini göstermektedir.

Zhang ve ark. (2020), dalgacık paket ayrıştırması ve aşırı makine öğrenmesini birleştiren çok adımlı bir rüzgar hızı tahmin sistemi önermektedir. Odak noktası dalgacık paket ayrıştırması ve aşırı makine öğrenmesi olsa da, çalışma, performansını artırmak için dalgacık sinir ağına Lorenz girişiminin eklenmesinden bahsetmektedir. Bu da dalgacık sinir ağlarının rüzgar hızı tahminindeki potansiyelini ortaya koymaktadır.

Berrezzek ve ark. (2019), DWT'nin rüzgar hızı tahmininde uygulanmasını tartışmaktadır. Çalışma, rüzgâr hızı zaman serisi verilerinin farklı frekans bileşenlerini çıkarmak için dalgacık ayrıştırması uygulamakta ve tahmin için bir YSA kullanmaktadır. Dalgacık sinir ağlarından açıkça bahsetmemesine rağmen, dalgacık ayrışımını rüzgar hızı tahmini için bir ön işleme adımı olarak vurgulamaktadır.


Özetle, rüzgâr hızı tahmini için dalgacık sinir ağlarına ilişkin doğrudan referanslar bulunmamakla birlikte, mevcut çalışmalar rüzgâr hızı tahmin doğruluğunu artırmak için farklı sinir ağı mimarilerini dalgacık ayrıştırma teknikleriyle birleştirme potansiyelini ortaya koymaktadır. Dalgacık sinir ağlarının rüzgar hızı tahminindeki özel uygulamalarını keşfetmek ve performanslarını diğer yaklaşımlarla karşılaştırmak için daha fazla araştırmaya ihtiyaç vardır.



3. MATERYAL VE YÖNTEM


3.1. Atmosferik verilerin sağlanması

Tez çalışmamızın bu safhasında işlenecek olan veri setinin basınç, sıcaklık, nem ve rüzgâr hızı verilerini sağlayacak, Tokat Gaziosmanpaşa Üniversitesi Taşlıçiftlik Kampüsü içerisine (N40°19'58.73") enlemi ve (E36°29'0.28") boylamına yerleştirilen ölçüm istasyonunda yer alan ölçüm direği Şekil 3.1'de gösterilmektedir.



Şekil 3.1. Ölçüm Direği

Ölçüm direği 12 m yüksekliğinde olup üzerinde 2 adet rüzgâr hızı ölçüm sensörü ve 1 adet rüzgâr yönü ölçüm sensörü bulunmaktadır. Basınç, sıcaklık ve nem sensörleri direğin alt kısmına montaj edilen güç kutusuna yerleştirilmiştir (Şekil 3.2). Sensörlerin ihtiyaç duyduğu enerji 10 W'lık solar panel ile sağlanmaktadır. Ayrıca başka çalışmalarda da kullanılmak üzere ölçüm direğinin üzerine AIR-X 400W rüzgâr türbini yerleştirilmiştir.



Şekil 3.2. Güç Kutusu

Coğrafi konuma ait rüzgâr hızı, basınç, sıcaklık ve nem verileri 2017 yılı itibariyle 10'ar dakika aralıklar ile kaydedilmeye başlanmış ve halen veri toplanmasına devam edilmektedir.

3.2. Veri Ayrıştırma Yöntemleri

Veri analizi alanında, veri ayrıştırma yöntemleri karmaşık veri kümelerinin analiz için daha basit, daha yönetilebilir parçalara ayrılmasında önemli bir rol oynar. Sinyal işleme, görüntü analizi ve makine öğrenimi gibi çeşitli alanlarda yaygın olarak kullanılan yöntemlerdir. Veri ayrıştırma yöntemleri, araştırmacıların ve uygulayıcıların karmaşık veri kümelerinden anlamlı

bilgiler çıkarmasına olanak tanıyan veri analizi alanında temel araçlardır. Her yöntemin kendine özgü güçlü yanları ve uygulamaları vardır ve yöntem seçimi veri kümesinin belirli özelliklerine ve analizin hedeflerine bağlıdır. Araştırmacılar bir veri ayrıştırma yöntemi seçerken verilerinin özelliklerini ve analizlerinin gerekliliklerini dikkatle değerlendirmelidir.

3.2.1. Ampirik Mod Ayrıştırma (EMD, Empirical Mode Decomposition)

Ampirik Mod Ayrıştırma (EMD), durağan olmayan ve doğrusal olmayan zaman serisi verilerini işlemek için kullanılan bir veri analizi yöntemidir. Huang ve arkadaşları tarafından 1990'ların sonunda bir sinyali İçsel Mod Fonksiyonları (IMF) olarak bilinen içsel salınım modlarına uyarlanabilir bir şekilde ayrıştırmanın bir yolu olarak geliştirilmiştir. EMD, sinyal işleme, finans ve biyomedikal sinyal analizi dahil olmak üzere çeşitli alanlarda uygulama alanı bulmuştur.

EMD, orijinal sinyalin IMF'ler olarak bilinen içsel salınım modlarının doğrusal bir kombinasyonu olarak temsil edildiği gerçek dünya sinyallerinin çok ölçekli ayrıştırılması ve zaman frekansı analizi için kullanılan veri odaklı bir yöntemdir (Rehman ve Mandic, 2009). EMD, rüzgar enerjisinin şebekeye entegrasyonu sırasında güç dalgalanmalarını ele almak için rüzgar hızı tahmininde yaygın olarak uygulanmıştır (Zhou, 2023). Bununla birlikte, EMD'nin doğrudan kullanımı büyük gürültü ve mod örtüşmesi gibi sorunlara yol açabilir (Shen ve ark., 2023). Rüzgar hızı sinyallerinin durağan olmamasını azaltmak için, uyarlanabilir gürültülü (ICEEMDAN, Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise), bulanık entropi ve varyasyonel mod ayrıştırma (VMD) ile geliştirilmiş tam topluluk ampirik mod ayrıştırmaya dayalı iki kez ayrıştırmayı içeren yeni bir yaklaşım önerilmiştir (Xia ve Wang, 2022). Ek olarak, rüzgar hızı tahmininin doğruluğunu artırmak için hızlı bir topluluk ampirik mod ayrıştırma modeli geliştirilmiştir (Wang, 2021).

Ayrıca, EMD veya EEMD modelleri, avantajları ve gelecekteki potansiyel uygulamaları nedeniyle rüzgar hızı ve güç tahmini için dikkat çekmiştir (Bokde ve ark., 2019). Bayesian Sırt Regresyonu ile birlikte topluluk ampirik mod ayrıştırmasının kullanımının, karmaşık rüzgar hızı zaman serilerini nispeten daha ılımlı, daha düzenli ve istikrarlı alt dizilere ayırdığı gösterilmiştir (Yang ve Yang, 2020). Ayrıca, çok değişkenli ampirik mod ayrışımı, rastgele

orman ve çekirdek sırtı regresyonunu içeren yeni geliştirilen bütünleştirici bir biyo-esinlenmiş yapay zeka modeli, rüzgar hızı tahmininde dikkate değer bir performans göstermiştir (Tao ve ark., 2020). Ayrıca, tam topluluk ampirik mod ayrıştırma uyarlanabilir gürültü, geçitli tekrarlayan birim ağı ve geliştirilmiş bir yarasa algoritmasına dayanan birleşik bir model, rüzgar hızı tahmininde umut verici sonuçlar göstermiştir (Liang ve ark., 2020).

Ampirik mod ayrıştırmanın rüzgar enerjisi verilerinin ayrıştırılması ve tahmini için etkinliği, yöntemin en büyük Lyapunov üstel tahmin yöntemi ve gri tahmin modeli gibi diğer tahmin teknikleriyle birlikte kullanılmasıyla gösterilmiştir (Zhang ve ark., 2019). Ayrıca, YSA'ların VMD ile kombinasyonu, kısa vadeli rüzgar hızı tahmini için sunulmuş ve bu yaklaşımın potansiyelini göstermiştir (Gendeel ve ark., 2018). Ayrıca, ampirik mod ayrıştırması, rüzgar hızı zaman serilerinin rastgeleliliğini azaltmak ve tahmin doğruluğunu artırmak için dalgacık dönüşümü ve varyasyonel mod ayrıştırması gibi diğer zaman serisi ayrıştırma yöntemleriyle birlikte kullanılmıştır (Huang ve ark., 2019).

Ampirik mod ayrıştırması ile topluluk ampirik mod ayrıştırması ve tam topluluk ampirik mod ayrıştırması uyarlanabilir gürültü gibi EMD varyantları, rüzgar hızı tahmini ve tahmininde yaygın olarak uygulanmaktadır. Bu yöntemler, rüzgar hızı sinyallerinin durağan olmamasını ele almada ve rüzgar hızı tahmininin doğruluğunu artırmada potansiyel göstermiştir.

Ampirik Mod Ayrıştırma işleminde yer alan temel adımlar şunlardır:

- Ayrıştırma: EMD bir sinyali bir dizi IMF'ye ayırır. Bir IMF, aynı sayıda sıfır geçişine ve ekstrema sahip bir fonksiyon olarak tanımlanır ve yerel maksimum ve minimumlar tarafından tanımlanan zarfın ortalama değeri sıfırdır. Her bir IMF sinyalin farklı bir frekans bileşenini temsil eder.
- Eleme Süreci: Ayrıştırma "eleme" adı verilen bir işlemle gerçekleştirilir. Eleme işleminin her bir iterasyonunda sinyalin yerel ortalaması hesaplanır ve bu ortalama daha sonra bir kalıntı elde etmek için orijinal sinyalden çıkarılır. Kalıntı daha sonra yeni bir sinyal olarak ele alınır ve elde edilen sinyal bir IMF olma kriterlerini karşılayana kadar işlem tekrarlanır.

- IMF'lerin çıkarılması: Eleme işlemi, orijinal sinyalden bir dizi IMF çıkarmak için yinelemeli olarak tekrarlanır. Her bir IMF, en yüksek frekanstan başlayarak en düşüğe doğru sinyalin farklı bir frekans bileşenini yakalar.
- Kalıntı: Tüm IMF'ler çıkarıldıktan sonra elde edilen son kalıntı, orijinal sinyalin trendini veya düşük frekanslı bileşenini temsil eder.

EMD'nin avantajlarından biri, bir sinyalin yerel özelliklerine uyarlanabilir olmasıdır, bu da onu durağan olmayan ve doğrusal olmayan bileşenlere sahip sinyalleri analiz etmek için özellikle yararlı kılar. Bununla birlikte, EMD'nin her zaman benzersiz olmadığını ve ayrıştırma sonuçlarının belirli uygulama ve parametre seçimlerine göre değişebileceğini belirtmek önemlidir.

EMD zaman içinde genişletilmiş ve modifiye edilmiştir ve bazı sınırlamaları ele almak ve ayrıştırma sürecinin sağlamlığını artırmak için Ensemble Empirical Mode Decomposition (EEMD) ve Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) gibi varyasyonlar önerilmiştir.

3.2.2. Topluluk Ampirik Mod Ayrıştırma (EEMD, Ensemble Empirical Mode Decomposition Method)

Topluluk Ampirik Mod Ayrıştırma (EEMD), orijinal EMD yönteminin bir uzantısıdır. EMD ile ilişkili bazı sınırlamaları ve zorlukları ele almak için geliştirilmiştir ve özellikle gürültü varlığında sinyallerin daha kararlı ve güvenilir bir şekilde ayrıştırılmasını sağlar.

EEMD'nin arkasındaki ana fikir, standart EMD işlemini uygulamadan önce sinyale bir beyaz gürültü gerçekleştirmeleri topluluğu eklemektir. EEMD, gürültü ekleyerek, özellikle EMD'nin mod karışımından muzdarip olabileceği gürültü veya diğer veri düzensizlikleri nedeniyle tutarsız sonuçlar üretebileceği durumlarda ayrıştırmanın sağlamlığını artırmayı amaçlamaktadır.

Topluluk Ampirik Mod Ayrıştırma yönteminde yer alan temel adımlar şunlardır:

- Topluluk Oluşturma: Bir sinyal topluluğu oluşturmak için orijinal sinyale birden fazla beyaz gürültü gerçekleşmesi eklenir. Her bir gerçekleşme, orijinal sinyale bağımsız ve aynı dağılımlı rastgele gürültü eklenerek elde edilir.
- Her Topluluk Üyesi için EMD: EMD işlemi, topluluktaki her sinyale bağımsız olarak uygulanır. Bu, her bir gerçekleşme için bir dizi İçsel Mod Fonksiyonu (IMF'ler) ile sonuçlanır.
- Mod Ortalaması Alma: Topluluğun her bir üyesinden elde edilen IMF'lerin nokta bazında ortalaması alınarak bir dizi topluluk ortalamalı IMF oluşturulur.
- Nihai Kalıntı Hesaplaması: Nihai kalıntı, her bir gerçekleşmeden elde edilen kalıntıların ortalaması alınarak elde edilir.

Topluluğun eklenmesi mod karışımının etkilerini azaltmaya yardımcı olur ve ayrıştırma sürecinin kararlılığını artırır. Sinyaldeki içsel salınım modlarının daha tutarlı bir temsilini sağlayarak EEMD'yi durağan olmayan ve gürültülü zaman serisi verilerini analiz etmek için sağlam bir yöntem haline getirir.

EEMD, EMD ile ilgili bazı sorunları ele alırken, topluluk üyelerinin sayısı ve eklenen gürültünün genliği gibi parametrelerin seçiminin sonuçları hala etkileyebileceğini belirtmek gerekir. Araştırmacılar, farklı uygulamalardaki performansını artırmak için uyarlanabilir gürültü ve diğer modifikasyonların eklenmesi gibi EEMD yöntemindeki varyasyonları ve iyileştirmeleri keşfetmeye devam etmişlerdir.

EEMD, durağan olmayan ve doğrusal olmayan zaman serisi verilerini işlemedeki etkinliği nedeniyle rüzgar hızı tahmini ve tahmininde yaygın olarak kullanılmaktadır. EEMD, tahmin doğruluğunu artırmak için çeşitli rüzgar hızı tahmin modellerinde uygulanan gürültü destekli bir veri analizi yöntemidir (Wu ve Huang, 2009; Wang ve ark., 2015; Wang ve ark., 2016; Ren ve ark., 2016; Zhi ve ark., 2016; Zhang ve ark., 2017; Kang ve ark., 2017; Chen ve ark., 2018; Lu ve ark., 2018; Huang ve ark., 2018; Huang ve ark., 2018; Sun ve Wang, 2018; Huang ve ark., 2019; Sun vd, 2019; Yang ve Yang, 2020; Jin ve ark., 2020; Xie ve ark., 2021; Saxena ve ark., 2021; Wang, 2021; Xia ve Wang, 2022; You ve ark., 2022; Zhu, 2022; Phan ve Tan, 2023;

Ai ve ark., 2023). EEMD tekniđi, altta yatan salınım modlarını yakalamak için orijinal rüzgar hızı verilerinin bir dizi IMF'lere ayrıştırılmasını ve daha sonra bu IMF'leri tahmin etmek için çeşitli tahmin modellerinin kullanılmasını içerir ve bunlar daha sonra nihai rüzgar hızı tahminini elde etmek için birleştirilir (Huang ve ark., 2018; Huang ve ark., 2019; Zhu, 2022).

Bazı çalışmalar, rüzgar hızı tahmin doğruluđunu artırmak için EEMD'yi dalgacık dönüşümü, LSSVM, LSTM, ARIMA, SVR ve meyve sineđi optimizasyon algoritması gibi diđer tekniklerle birleştiren hibrit modeller önermiştir (Wang ve ark., 2016; Zhi ve ark., 2016; Huang ve ark., 2018; Lu ve ark., 2018; Sun ve ark., 2019; Huang ve ark., 2019; Xia ve Wang, 2022; You ve ark., 2022; Su ve ark., 2023; Ai ve ark., 2023). Bu hibrit modeller, EEMD'nin durađan olmama durumunu ele almadaki güçlü yönlerinden ve rüzgar hızı verilerinin farklı yönlerini yakalamak için diđer yöntemlerin tamamlayıcı yeteneklerinden yararlanarak daha sağlam ve doğru tahminlere yol açmaktadır.

Ayrıca, EEMD, rüzgar hızını tahmin etmek için Kapı Özyinelemeli Geçitler (GRU, Gated Recurrent Units) ve LSTM gibi derin öğrenme modelleriyle birlikte kullanılmış ve EEMD'nin gelişmiş tahmin teknikleriyle entegre olma konusundaki çok yönlülüđünü göstermiştir (Huang ve ark., 2018; Huang ve ark., 2019; Xie ve ark., 2021; Saxena ve ark., 2021). Ayrıca EEMD, parametre optimizasyon sürecini geliştirmek ve genel tahmin performansını iyileştirmek için genetik algoritma, yerçekimsel arama algoritması (GSA, Gravitational Search Algorithm) ve guguk kuşu arama optimizasyon algoritması gibi optimizasyon algoritmalarıyla birleştirilmiştir (Zhi ve ark., 2016; Zhang ve ark., 2017; Lu ve ark., 2018; Sun ve ark., 2019).

Literatür EEMD'nin rüzgar hızı tahmini ve tahmininde yaygın olarak kullanıldığını göstermekte, hibrit modellere uyarlanabilirliğini ve rüzgar hızı verilerinin karmaşıklığını ele almadaki etkinliğini ortaya koymaktadır.

1 Ocak 2020 tarihine ait basınç (Şekil 7.8), sıcaklık (Şekil 7.9) ve nem (Şekil 7.10) verilerine ait EEMD ayrıştırma yöntemi görselleri “Ekler” bölümünde verilmiştir.

3.2.3. Tamamlayıcı Topluluk Ampirik Mod Ayrıştırma (CEEMD, Complementary Ensemble Empirical Mode Decomposition)

Tamamlayıcı Topluluk Ampirik Mod Ayrıştırma (CEEMD), EMD'deki mod karıştırma sorununu ele alan gürültü ile geliştirilmiş bir veri analizi yöntemidir (Yeh ve ark., 2010). CEEMD, beyin haritalama, kuraklık tahmini, yağış tahmini, yapısal sağlık izleme, arıza teşhisi ve titreşim tabanlı yapısal sağlık izleme gibi çeşitli alanlarda uygulanmıştır (Qian ve ark., 2015; Liu ve ark., 2020; Li ve ark., 2021; Xu ve ark., 2022; Zhang ve ark., 2022; Eltouny ve ark., 2023). Ayrıca endüksiyon motorlarının durumunun izlenmesinde ve gaz yalıtımlı şalt ekipmanlarındaki mekanik kusurların belirlenmesinde de kullanılmıştır (Valtierra-Rodriguez ve ark., 2019; Zhong ve ark., 2020; Bian ve ark., 2020). Yöntem, kuraklık tahmini için ARIMA ve kusur tanımlama için genetik algoritma geliştirilmiş çekirdek bulanık ortalama kümeleme gibi diğer tekniklerle birleştirilmiştir (Zhong ve ark., 2020; Xu ve ark., 2022). CEEMD'nin mod karıştırma problemini etkili bir şekilde ele aldığı ve orijinal verileri farklı frekanslara sahip daha durağan sinyallere ayırdığı gösterilmiştir (Wu ve ark., 2019).

CEEMD ayrıca deniz seviyesindeki doğrusal olmayan eğilimlerin, uçak arıza oranının ve ham petrol fiyatının tahmininde de kullanılmıştır (Tang ve ark., 2015; Zhao ve ark., 2019; Li ve Hou, 2022). Normal deneklerde ve tinnitus hastalarında kararlı durum işitsel uyarılmış alanların çıkarılmasında ve sürtünme sinyallerinin denoize edilmesinde kullanılmıştır (Wang ve ark., 2015; Li ve ark., 2015). Ayrıca, CEEMD hidrolik pompalarda arıza teşhisi ve rulmanlı yataklarda arıza tanıma için kullanılmıştır (Zhao ve ark., 2016; Li ve Ding, 2016). Yöntem, anlık sismik özniteliklerin temassız ölçümü ve tespiti ile sismik verilerdeki spektral desenlerin tanımlanmasına uygulanmıştır (Kwietniak ve ark., 2016; Huang ve ark., 2017).

Ayrıca, CEEMD beyin ağlarının analizinde, deniz yüzeyi sıcaklığının tahmininde ve genelleştirilmiş tonik-klonik nöbetlerdeki fonksiyonel merkezlerin tanımlanmasında kullanılmıştır (Qian ve ark., 2015; Zhang ve ark., 2016; Wu ve ark., 2019). Ayrıca konuşma sinyallerinin gürültüsüz işlenmesi için konuşma tanıma alanında da uygulanmıştır (Казанферович ve Churakov, 2015). Yöntem, farklı uygulamalardaki yeteneklerini geliştirmek için Radyal Taban Fonksiyonu Ağı (RBFN, Radial Basis Function Network), parçacık sürüsü optimizasyonu (PSO) ve destek vektör makinesi (SVM) gibi çeşitli algoritmalarla birleştirilmiştir (Li ve Ding, 2016; Zhao ve ark., 2019; Liu ve ark., 2020).

Genel olarak, CEEMD'nin EMD'deki mod karıştırma sorunlarını ele almak için çok yönlü ve etkili bir yöntem olduğu kanıtlanmıştır ve sinyalleri farklı frekans bantlarına sahip içsel salınım ritimlerine ayırıştırma yeteneği nedeniyle çeşitli alanlarda yaygın bir uygulama alanı bulmuştur.

3.2.4. Uyarlanabilir Gürültülü Tam Topluluk Ampirik Mod Ayırıştırması (CEEMDAN, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise)

Rüzgar hızı tahminini geliştirmek için, çeşitli çalışmalar EEMD ve Uyarlanabilir Gürültülü Tam Topluluk Ampirik Mod Ayırıştırması (CEEMDAN) gibi gelişmiş sinyal işleme tekniklerinin kullanılmasını önermiştir (Sun ve ark., 2019; Chen ve ark., 2020; Wang, 2021; Xia ve Wang, 2022). Bu yöntemler, orijinal rüzgar hızı verilerini daha durağan alt serilere ayırmayı ve böylece rüzgar hızı tahmin modellerinin doğruluğunu artırmayı amaçlamaktadır. Ek olarak, EEMD kullanımının rüzgar hızını etkili bir şekilde kararlı sinyallere ayıştırdığı ve kısa vadeli rüzgar hızı tahmininin iyileştirilmesine katkıda bulunduğu gösterilmiştir (Huang ve ark., 2018; Xie ve ark., 2021). Ayrıca, CEEMDAN uygulamasının rüzgar gücünü doğru bir şekilde tahmin etmede etkili olduğu gösterilmiştir, bu da rüzgar hızı tahminini geliştirme potansiyelini göstermektedir (You ve ark., 2022).

Ayrıca, rüzgar hızı verilerini daha düzenli hale getirmek ve böylece rüzgar hızı tahmin modellerinin doğruluğunu artırmak için VMD gibi sinyal ayırıştırma tekniklerinin kullanımı araştırılmıştır (Vanitha ve ark., 2020). Ayrıca, EMD ve geliştirilmiş LSSVM kombinasyonu, rüzgar hızı tahmin doğruluğunu artırmak için hibrit bir tahmin yöntemi olarak önerilmiştir (Sun ve Yang, 2013). Bu yaklaşımlar, rüzgar hızı tahmin modellerinin iyileştirilmesinde gelişmiş sinyal işleme tekniklerinin potansiyelini vurgulamaktadır.

Ayrıca, literatür, filtreleme performansını iyileştirmek için süreç gürültüsü kovaryansını ve ölçüm gürültüsü kovaryansını uyarlamalı olarak ayarlayabilen Kalman filtresi gibi uyarlamalı algoritmaların kullanılmasıyla rüzgar hızı tahmininin geliştirilebileceğini göstermektedir (Huang ve ark., 2019). Ayrıca, Genişletilmiş Kalman Filtresi (EKF, Extended Kalman Filter) ile birlikte sinir ağlarının kullanımının rüzgar hızını başarılı bir şekilde tahmin ettiği gösterilmiştir, bu da uyarlanabilir algoritmaların rüzgar hızı tahminini geliştirme potansiyelini daha da göstermektedir (Hur, 2019).

Ampirik Mod Ayırıştırması ve türevlerine ait avantajlar ve deavantajlar Tablo 3.1’de verilmiştir.

Özetle, literatür, rüzgar hızı tahmin doğruluğunu artırmak için EEMD, CEEMDAN, VMD gibi gelişmiş sinyal işleme tekniklerinin ve Kalman filtresi ve sinir ağları gibi uyarlanabilir algoritmaların kullanımını desteklemektedir. Bu yöntemler, yenilenebilir enerji sektöründeki çeşitli uygulamalar için çok önemli olan rüzgar hızı tahmin modellerinin hassasiyetini artırmak için umut verici yollar sunmaktadır.

Tablo 3.1. EMD ve geliştirilmiş versiyonlarının karşılaştırılması. (Qian ve ark., 2019)

METOT	AVANTAJLARI	DEZAVANTAJLARI
EMD	Adaptif	Mod karıştırma
EEMD	Adaptif; Mod karıştırma problemini çözübilir.	Yeniden oluşturulan sinyallerde ekstra gürültü vardır; Çok fazla hesaplama kaynağına ihtiyaç vardır.
CEEMD	Adaptif; Mod karıştırma problemini çözübilir; Yeniden oluşturulan sinyallerde ekstra gürültü yoktur.	Çok fazla hesaplama kaynağına ihtiyaç vardır.
CEEMDAN	Adaptif; Mod karıştırma problemini çözübilir; Yeniden oluşturulan sinyallerde ekstra gürültü yoktur.	Sıralı prosedür, paralel hesaplama ile gerçekleştirilemez.

1 Ocak 2020 tarihine ait basınç (Şekil 7.1), sıcaklık (Şekil 7.2) ve nem (Şekil 7.3) verilerine ait CEEMDAN ayırıştırma yöntemi görselleri “Ekler” bölümünde verilmiştir.

3.2.5. Yerel Ortalama Ayırıştırması (LMD, Local Mean Decompositon)

Yerel Ortalama Ayırıştırma (LMD), dalgacık ayırıştırma ve EMD gibi diğer yöntemlerin yanı sıra rüzgar hızı verilerini ayırştırmak için önemli bir yöntemdir (Tian ve ark., 2019). Ortalama aylık rüzgar hızını tahmin etmek için LMD ve LSSVM kullanan hibrit bir model önermiş ve LMD'nin rüzgar hızı tahmininde uygulanabilirliğini göstermiştir (Tuerxun ve ark., 2022). Ayrıca, LMD rüzgar türbinleri için arıza teşhis yöntemlerinde kullanılarak rüzgar enerjisi uygulamalarındaki çok yönlülüğünü göstermiştir (Liu ve ark., 2012).

Ayrıca, LMD'nin rüzgar hızı tahmininde kullanımının, rüzgar hızı zaman serilerinin düzensiz ve değişken doğasını yakalamada etkili olduğu gösterilmiştir, bu da onu rüzgar hızı tahmini için umut verici bir yaklaşım haline getirmektedir (Giorgi ve ark., 2014). Ayrıca, LMD ile ilgili olan Hilbert-Huang dönüşümü, durağan olmama durumunu ele alma kabiliyeti nedeniyle rüzgar hızı zaman serilerinin spektral analizi için seçilmiştir ve bu da LMD'nin rüzgar hızı analizindeki uygunluğunu daha da vurgulamaktadır (Vincent ve ark., 2010).

Ayrıca, rüzgar hızı ve güç tahmini çalışmalarında ayırıştırma seviyesi genellikle küçük bir sayı ile sınırlıdır, bu da LMD'nin gerçek dünya tahmin senaryolarında pratik hususları ve uygulanabilirliğini vurgulamaktadır (Taşçıkaraoğlu ve ark., 2016). LMD'nin rüzgar hızı tahminindeki etkinliği, (Chen ve ark., 2013) tarafından gösterildiği gibi, diğer modellere kıyasla tahmin doğruluğundaki iyileşmede de açıkça görülmektedir.

Özetle, LMD rüzgar hızı tahmin modellerinde yaygın olarak kullanılmış ve rüzgar hızı verilerinin karmaşık ve durağan olmayan doğasını yakalamadaki etkinliğini göstermiştir. Hibrit modellerde ve arıza teşhis yöntemlerinde uygulanması, rüzgar enerjisi araştırmaları alanındaki çok yönlülüğünü ve uygunluğunu göstermektedir.

1 Ocak 2020 tarihine ait basınç (Şekil 7.15), sıcaklık (Şekil 7.16) ve nem (Şekil 7.17) verilerine ait LMD ayırıştırma yöntemi görselleri “Ekler” bölümünde verilmiştir.

3.2.6. Varyasyonel Mod Ayırıştırma (VMD, Variational Mode Decomposition)

Rüzgar hızı tahmininde Varyasyonel Mod Ayırışımı (VMD) uygulaması, rüzgar hızı verilerini uzun vadeli, dalgalanma ve rastgele bileşenler gibi kurucu modlara ayırma kabiliyeti nedeniyle

rüzgar hızı tahmini ve güç tahmininde yaygın olarak kullanılmaktadır (Han ve ark., 2019; , Zhang ve ark., 2022). VMD, rüzgar hızı tahmin doğruluğunu artırmak için YSA'lar, destek SVR ve derin öğrenme modelleri gibi çeşitli tekniklerle entegre edilmiştir (Ren ve ark., 2015; , Heydari ve ark., 2021; , Zhou ve ark., 2018; , Wang ve ark., 2021; , Vanitha ve ark., 2020). Ayrıca, VMD, bir enerji depolama sisteminin referans gücünü ayırtmak ve rüzgar gücü verilerinin farklı dalgalanma özelliklerini çıkarmak için kullanıldığı rüzgar gücü dalgalanma sinyali işleme bağlamında kullanılmıştır (Zhou, 2023; , Zhang ve ark., 2021).

Ayrıca VMD, rüzgâr türbinlerinin arıza teşhisi gibi rüzgâr hızı tahmininin ötesinde uygulamalar da bulmuştur. Örneğin, rüzgar türbinlerinde rulman arızası teşhisi için her frekans bandının enerjisini çıkarmak için bir ön işlemci olarak kullanılmış ve rüzgar enerjisi alanındaki çok yönlülüğünü göstermiştir (An ve Tang, 2016; Maheswari ve Umamaheswari, 2019). Ayrıca VMD, rüzgâr hızını ve gücünü alternatif olarak ayırtmak için dalgacık dönüşümü gibi diğer ayırtma yöntemleriyle entegre edilmiş ve tahmin modellerine girdi olarak kullanılmak üzere farklı frekans bandı bileşenlerinin çıkarılmasına yol açmıştır (Lang, 2021).

Sonuç olarak, VMD, rüzgar hızı verilerini çeşitli bileşenlere ayırma ve çeşitli tahmin ve arıza teşhis teknikleriyle entegre etme yeteneği sunarak rüzgar hızı tahmini ve rüzgar gücü tahmininde değerli bir araç olduğunu kanıtlamıştır. Çok yönlülüğü ve etkinliği, onu rüzgar enerjisi araştırmaları alanında öne çıkan bir yöntem haline getirmektedir.

1 Ocak 2020 tarihine ait basınç (Şekil 7.36), sıcaklık (Şekil 7.37) ve nem (Şekil 7.38) verilerine ait VMD ayırtma yöntemi görselleri “Ekler” bölümünde verilmiştir.


3.3. Yapay Sinir Ağları

Biyolojik sinir ağları, canlı organizmalardaki sinir sistemlerini ifade eder. Sinir ağları, sinir hücrelerinin (nöronlar) bir araya gelerek bilgi işleme, iletim ve depolama görevlerini yerine getirdiği kompleks ağlar olarak tanımlanır. İnsanlar ve diğer hayvanlar üzerinde gözlemlenen sinir ağları, biyolojik sistemlerin bilgi işleme kapasitelerinin temelini oluşturur.

Biyolojik sinir ağıları hakkında genel bilgiler:

- Nöronlar: Sinir hücreleri veya nöronlar, sinir ağlarının temel yapı taşlarıdır. Nöronlar, sinir impulslarını alabilir, işleyebilir ve diğer nöronlara veya hücrelere iletebilir. Her nöron, bir hücre gövdesi, bir akson (uzun iletişim lifi) ve dendritler (sinir impulslarını almak için kısa uzantılar) gibi temel yapıları içerir. Nöron (sinir hücresi) yapısı Şekil 3.3’de verilmiştir.
- Sinir İmpulsları: Sinir ağıları, elektriksel ve kimyasal sinyallerin iletilmesi üzerine kuruludur. Bir nöronun uyarılması sonucunda oluşan elektriksel sinyaller, akson boyunca iletilir ve hedef nöronlara veya hücrelere kimyasal sinyaller (sinir iletimi) aracılığıyla iletilir.
- Sinir Sistemi Bileşenleri:
 - Merkezi Sinir Sistemi (MSS): Beyin ve omurilikten oluşur. Bilgi işleme ve karar alma işlevlerini gerçekleştirir.
 - Periferik Sinir Sistemi (PSS): Organizmanın geri kalan kısmı ile merkezi sinir sistemi arasında bilgi iletimini sağlar. PSS, duyu ve motor sinirleri içerir.
- Sinir Ağlarının İşlevleri:
 - Duyu İşleme: Çevresel uyaranları algılar ve bu bilgileri merkezi sinir sistemine iletir.
- Motor İşlevler: Merkezi sinir sisteminin aldığı bilgileri temel alarak kaslara yönlendirilen hareket sinyallerini üretir.
- Bellek ve Öğrenme: Sinir ağıları, bilgileri depolar ve deneyimlerden öğrenme yeteneğine sahiptir.
- Plastisite: Biyolojik sinir ağıları, plastisite adı verilen bir özellikleri sayesinde çevresel değişikliklere uyum sağlayabilir. Plastisite, sinir ağlarının bağlantılarını güçlendirme veya zayıflatma yeteneğini ifade eder.

Biyolojik sinir ağıları, yapısı ve işlevselliği bakımından son derece karmaşık ve adaptif sistemlerdir. Bu doğal sistemler, yapay sinir ağıları olarak bilinen matematiksel ve bilgisayar tabanlı modellerin ilham kaynağı olmuştur. Yapay sinir ağıları, bilgisayar biliminde öğrenme ve problem çözme uygulamalarında kullanılan yapay modellemelerdir. (Öztemel, 2003)



Şekil 3.3. Nöron (sinir hücresi) yapısı

Sinir sisteminde bilgi iletimi, sinir hücreleri veya nöronlar arasında elektriksel ve kimyasal sinyallerin iletilmesi üzerine kuruludur. Bu iletim süreci, genellikle şu ana adımlardan oluşur:

- Dendritlerde Sinir İmpulsu Alınması:

Bir sinir hücresi genellikle birden fazla dendrite sahiptir. Dendritler, çevresel uyarılardan gelen sinir impulslarını alır. Dendritler, bu gelen sinyalleri sinir hücresinin hücre gövdesine (soma) taşır.

- Sinir Hücresinin Uyarılması:

Dendritlerden gelen sinir impulsları, sinir hücresinin hücre gövdesinde toplanır. Eğer toplam sinyal şiddeti, bir eşik değeri aşarsa, sinir hücresi uyarılır.

- Aksiyon Potansiyeli Oluşumu:

Uyarılmış bir sinir hücresinde, hücre zarında bir aksiyon potansiyeli oluşur. Bu aksiyon potansiyeli, hücre zarındaki iyonların geçişine dayanır ve bir elektriksel sinyal olarak iletilir.

- Akson Boyunca İletim:

Aksiyon potansiyeli, nöronun aksonu boyunca iletilir. Akson, nöronun uzun uzantısıdır ve sinir impulslarını diğer nöronlara veya hücrelere taşır.

- Sinaptik Boşlukta Kimyasal İletim:


Sinir impulsları, aksonun sonundaki bir sinaptik boşluk adı verilen bölgeye ulaşır. Sinaptik boşluk, iki nöron arasındaki boşluğu ifade eder. Sinir impulsları, burada kimyasal bir haberci madde olan nörotransmitterlerin salınması ile kimyasal bir ilettime dönüşür.

- Dendritlerde Yeni Bir Sinir İmpulsu Oluşumu:

Nörotransmitterler, sonraki nöronun dendritlerine bağlanarak elektriksel sinyallerin iletimini başlatır. Bu süreç, sinir impulslarının bir nöron dan diğerine geçişini sağlar.


Bu adımlar, sinir sistemi içinde bilgi iletimini temsil eder. Sinir hücreleri arasındaki iletişim, elektriksel sinyallerin sinir hücresi içinde, akson boyunca ve sinaptik boşlukta kimyasal sinyallere dönüştüğü karmaşık bir süreçtir. Sinir sisteminin bu dinamik yapısı, çeşitli uyarılara hızlı ve hassas bir şekilde yanıt verme yeteneğini sağlar. (Öztemel, 2003)

Nöronlarda bilgi iletiminin oluşabilmesi için, impuls genliğinin belirli bir eşik seviyenin üzerine çıkması gerekmektedir. Şekil 3.4, impulsın iletilebilmesi için gereken eşik seviyeyi göstermektedir (Poznyak ve ark., 2001).



Şekil 3.4. Nöronda eşik değeri gösterimi (Poznyak et al., 2001)

Genliği eşik seviyesinin üzerine çıkan impuls, akson boyunca iletilir. Bu olay, akson içinde bulunan potasyum iyonlarının, miyelin kılıf etrafında bulunan sodyum iyonları ile yer değiştirmesi ile gerçekleşir. Şekil 3.5, impulsun akson üzerinde iletimini göstermektedir (Poznyak et al., 2001).



Şekil 3.5. Akson üzerinde bilgi iletimi

Nöron modeli

YSA, beynin öğrenme sürecini taklit etmek için tasarlanmış, insan beyninin nöronlarından ilham alan hesaplama sistemleridir (Yusmartato ve ark., 2018). Bu ağlar, akıllı algoritmalar kullanarak büyük miktarda veriyi işleyen ve analiz eden, hızlı bilgi işlemeyi sağlayan birbirine bağlı nöronlardan oluşur (Jafari ve ark., 2020). Bir YSA'nın temel birimi olan nöron, bu ağlarda çok önemli bir rol oynamaktadır. Sigmoid fonksiyon nöronu, radyal bazlı fonksiyon (RBF, Radial Basis Function) nöronu ve polinom nöronu gibi farklı nöron türleri, tıbbi görüntü teşhisi gibi görevler için hibrit geri beslemeli Veri İşleme Grup Yöntemi (GMDH, Group Method Of Data Handling) tipi sinir ağı algoritmalarında kullanılmaktadır (Kondo ve ark., 2015). Ayrıca, temel birim olarak ferroelektrik kapasitör kullanan FeNeuron gibi yeni nöron modellerinin geliştirilmesi, yapay nöron modelleri oluşturmaya yönelik çeşitli yaklaşımları sergilemektedir (Guerreiro ve ark., 2007).

YSA'ların performansı büyük ölçüde kullanılan öğrenme algoritmalarına bağlıdır. Yaygın olarak kullanılan bir öğrenme algoritması olan geri yayılım, bağlantı ağırlıklarını ayarlamak için hataların ağ boyunca geriye doğru yayılmasını içerir ve ağı temsil eden öğrenmesini sağlar

(Rumelhart ve ark., 1986). Ayrıca, nöronlarda farklı aktivasyon fonksiyonlarının kullanılmasının YSA'ların hesaplama gücünü artırdığı gösterilmiştir, bu da nöronun davranışının ağ performansındaki önemini göstermektedir (Kampakis, 2014).

Son yıllarda, YSA'lar için alternatif nöron modellerini keşfetmeye yönelik artan bir ilgi vardır. Örneğin, yapay nöronların kuantum hesaplama modellerinin geliştirilmesi ve sivri kuantum nöronlarının araştırılması, bu alandaki sürekli yeniliği göstermektedir (Mangini, 2020; Kristensen ve ark., 2019). Ayrıca, memristörlerin yapay nöronlara entegrasyonu, gelişmiş bilişsel işlevlere sahip nöromorfik akıllı bilgisayarlar geliştirme potansiyeli nedeniyle yoğun ilgi görmüştür (Wu ve ark., 2022).

Özetle, yapay nöron modellerinin incelenmesi, YSA'ların yeteneklerini geliştirmek için çok önemlidir. Geleneksel nöronlardan kuantum ve memristör tabanlı nöronlara kadar çok çeşitli nöron modelleri, YSA'ların hesaplama gücünü ve verimliliğini artırmaya yönelik sürekli çabaları yansıtmaktadır.

YSA, biyolojik sinir ağlarından ilham alınarak tasarlanmış matematiksel ve istatistiksel modellerdir. Yapay sinir ağları, geniş bir uygulama yelpazesi olan makine öğrenmesi ve yapay zeka alanlarında kullanılır. Bu ağlar, genellikle katmanlar, nöronlar ve ağırlıklar arasındaki bağlantılar gibi bileşenler içerir.

3.3.1. İleri Beslemeli Sinir Ağları (FNN, Feedforward Neural Networks):

Bu tip ağlarda bilgi, bir yönden diğerine doğru ilerler. Bilgi akışı, giriş katmanından başlayarak gizli katman(lar) üzerinden çıkış katmanına doğru devam eder. Giriş katmanındaki nöronlar, veriyi alır, ardından gizli katmanlar ve sonunda çıkış katmanına ulaşır (Şekil 3.6).


İleri Beslemeli Sinir Ağları (FNN), örüntü tanıma, sınıflandırma, fonksiyon yaklaşımı ve kontrol teorisindeki karmaşık problemleri çözme yetenekleri nedeniyle çeşitli alanlarda yaygın olarak çalışılmış ve uygulanmıştır (Nasr ve Chtourou, 2006). FNN'nin evrensel yaklaşım özelliği, küçük bir hata payı ile herhangi bir diferansiyel denkleme çözüm sağlamalarına olanak tanır (Guasti ve Santos, 2021). Ayrıca, FNN'nin sürekli fonksiyonlara yaklaşabildiği

gösterilmiştir, bu da onları çok çeşitli uygulamalar için uygun hale getirmektedir (Panahian ve Zainuddin, 2015).

İki boyutlu şekil değişkenliği için tasarlanmış özel bir FNN türü olan CNN'lerin belge tanıma sistemlerinde diğer tekniklerden daha iyi performans gösterdiği gösterilmiştir (LeCun ve ark., 1998). Ayrıca, benzer büyüklükteki katmanlara sahip standart FNN'lerle karşılaştırıldığında, CNN'lerin daha az bağlantı ve parametreye sahip olması, eğitilmelerini kolaylaştırırken yalnızca biraz daha kötü performans elde etmelerini sağlar (Krizhevsky ve ark., 2017). Bu, CNN'lerin 2 boyutlu şekil değişkenliğini ele almadaki etkinliğini ve eğitimdeki verimliliğini vurgulamaktadır.

Kontrol teorisi bağlamında, paralel fizik güdümlü sinir ağları (PGNN, Physics-induced Graph Neural Network), doğrusal motorları kontrol etmek için model tabanlı temel fonksiyonların özellik olarak kullanıldığı ileri beslemeli kontrol için kullanılmıştır (Kon ve ark., 2022). Bu, doğrusal olmayan sistemlerde etkili kontrol elde etmek için fizik güdümlü modellerle entegre edilebildikleri kontrol uygulamalarında FNN'nin çok yönlülüğünü göstermektedir.

Ayrıca, FNN eğitim problemlerinde Hessian'ların kötü koşullandırılması tespit edilmiştir, bu da FNN'nin eğitim sürecinde ele alınması gereken yaygın bir sorun olan kötü koşullandırılmış Hessian'lara sahip olabileceğini göstermektedir (Saarinen ve ark., 1993). Bu durum, FNN ile çalışırken eğitim dinamiklerini ve sayısal kararlılığı göz önünde bulundurmanın önemini vurgulamaktadır.



Şekil 3.6. İleri Beslemeli Sinir Ağı Mimarisi

Özetle, CNN'ler de dahil olmak üzere FNN'lerin örüntü tanımadan kontrol teorisine kadar geniş bir yelpazedeki problemleri çözmek için güçlü araçlar olduğu kanıtlanmıştır. Evrensel yaklaşım özellikleri, eğitimdeki verimlilikleri ve çeşitli alanlardaki uygulanabilirlikleri, onları yapay zeka ve mühendislik alanında değerli bir varlık haline getirmektedir.

3.3.2. Yinelemeli Sinir Ağları (RNN, Recurrent Neural Networks):


Yinelemeli Sinir Ağları (RNN'ler), içerdikleri döngüsel bağlantılar sayesinde geriye doğru döngü yapabilirler. Bu, geçmiş bilgileri hafızasında saklayabilme ve bu bilgileri gelecekteki durumları tahmin etme yeteneği sağlar. RNN'ler genellikle zaman serisi verileri ve doğal dil işleme gibi sıralı veri problemleri için kullanılır. Yinelemeli Sinir Ağı Yapısı Şekil 3.7'de verilmiştir.

RNN'ler, sıralı verileri verimli bir şekilde modelleme yetenekleri nedeniyle büyük ilgi görmüştür (Lee ve ark., 2018). Ancak, RNN'lerin eğitimi, kaybolan ve patlayan gradyanlar gibi sorunlar nedeniyle zor olabilir (Pascanu, 2012). Bu zorlukların üstesinden gelmek için araştırmacılar RNN'lerdeki farklı tekrarlayan birim türlerini karşılaştırmıştır (Chung, 2014). RNN'leri geliştirmeye yönelik bir yaklaşım, dil modelleme Mikolov ve Zweig (2012) ve güç

yükü tahmini (Feng ve ark., 2022) gibi görevlerde gelişmiş performans gösteren Uzun Kısa Süreli Bellek (LSTM) ağları gibi varyantların geliştirilmesidir. Ayrıca, girdi dizilerinin hem geçmiş hem de gelecek bağlamındaki bağımlılıkları yakalamak için çift yönlü RNN'ler önerilmiştir (Schuster ve Paliwal, 1997).

RNN'ler konuşma tanıma, doğal dil işleme ve zaman serisi tahmini gibi çeşitli alanlarda başarıyla uygulanmıştır (Cao ve ark., 2017). Ayrıca, RNN'lerin konuşma dizilerini doğrudan modellemedeki sınırlamalarının vurgulandığı konuşma ayırma gibi görevlerde de kullanılmıştır (Chen ve ark., 2020). Ayrıca, RNN'ler, optik müzik tanıma için artık tekrarlayan evrişimli RNN'lerin geliştirilmesi gibi belirli zorlukları ele almak için genişletilmiştir (Liu ve ark., 2021).

Belirli alanlardaki uygulamalarına ek olarak, RNN'ler, göreceli güçlü ve zayıf yönlerini anlamak için ileri beslemeli ağlar gibi diğer sinir ağı modelleriyle karşılaştırılmıştır (Sundermeyer ve ark., 2013). Ayrıca, RNN'ler, LSTM ve Gated Recurrent Unit (GRU) gibi RNN varyantlarının yorumlanabilirliğinin ve uygulamasının araştırıldığı lityum-iyon piller için şarj durumu tahmini gibi tahmin görevlerinde kullanılmıştır (Qiao ve ark., 2022).



Şekil 3.7. Yinelemeli Sinir Ağı Yapısı

Genel olarak, RNN'ler sıralı verilerin modellenmesinde etkili olduklarını göstermiştir, ancak devam eden araştırmalar eğitim zorluklarını ele almayı ve çeşitli uygulamalar için yeteneklerini genişletmeyi amaçlamaktadır.

3.3.3. Derin Öğrenme Modelleri:

Yapay sinir ağlarının derinleştirilmiş versiyonları, derin öğrenme modellerini oluşturur. Derin öğrenme modelleri, genellikle çok sayıda gizli katman içeren derin sinir ağlarını içerir ve geniş veri setleri üzerinde karmaşık desenleri öğrenme yeteneğine sahiptir.

Derin öğrenme modelleri, özellikle yapay sinir ağlarına dayalı olanlar, çeşitli alanlarda önemli ölçüde ilgi ve uygulama kazanmıştır. En önde gelen derin öğrenme modellerinden biri, özellikle 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'ndaki başarısından sonra bilgisayarla görme görevlerinde dikkate değer bir performans sergileyen evrişimli sinir ağıdır (CNN) (Krizhevsky ve ark., 2017). Derin öğrenme, daha karmaşık öğrenme ve özellik çıkarma sağlayan çok katmanlı ağların kullanılmasıyla karakterize edilen geleneksel yapay sinir ağlarının bir ilerlemesini temsil etmektedir (Shen ve ark., 2017). Büyük, derin evrişimli sinir ağları gibi derin öğrenme modellerinin yüksek çözünürlüklü görüntüleri sınıflandırmadaki başarısı, çeşitli uygulamalardaki önemini daha da artırmıştır (Krizhevsky ve ark., 2017).

Dahası, derin öğrenme, uçtan uca takviye öğrenme kullanarak yüksek boyutlu duyuşal girdilerden doğrudan başarılı politikalar öğrenebilen derin Q-ağları gibi yeni yapay ajanların geliştirilmesinde etkili olmuştur (Mnih ve ark., 2015). Ancak, ilerlemelere rağmen, yapay sinir ağlarına dayalı derin öğrenmenin, kara kutu doğası nedeniyle hala anlaşılması zor olduğu düşünülmektedir (Nguyen ve ark., 2022). Bununla birlikte, başta CNN'ler olmak üzere derin öğrenme teknolojisinin yaygın kullanımı, görüntü tanıma, tıbbi görüntü analizi ve geomatik uygulamaları gibi çeşitli alanlarda kendini göstermektedir (Ting ve ark., 2019; Yang ve ark., 2021; Serwa, 2022).

Derin öğrenme modellerinin uygulanması tıp, biyoloji ve siber güvenlik gibi çeşitli alanlara uzanmaktadır. Örneğin, derin öğrenme algoritmaları tıbbi görüntü analizinde, çeşitli hastalıklar için tanı modellerinde ve metagenomik verilerden antibiyotik direnç genlerinin tahmin edilmesinde giderek daha fazla kullanılmaktadır (Arango-Argoty ve ark., 2018; Ting ve ark., 2019). Ayrıca, yapay çok katmanlı sinir ağlarının başarısı, yapay sinir ağı teorisini biyolojik sinir ağlarına genişletme çabalarına yol açarak derin öğrenme modellerinin geniş etkisini ve potansiyelini göstermiştir (Bardwell, 2020).

Özetle, başta CNN'ler olmak üzere yapay sinir ağlarına dayalı derin öğrenme modelleri, bilgisayarla görme ve tıbbi görüntü analizinden siber güvenlik ve geomatik uygulamalarına kadar çeşitli alanlarda devrim yaratmıştır. Derin öğrenme modellerinin çok katmanlı mimarisi, karmaşık öğrenmeye ve özellik çıkarımına olanak tanıyarak yaygın olarak benimsenmelerine ve çeşitli alanlarda önemli etkilere yol açmaktadır.

3.3.4. Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN):


CNN'ler genellikle görsel veri analizi gibi alanlarda kullanılır. Bu ağlar, evrişim katmanları içerir ve bu katmanlar, görüntü üzerinde özelliklerin (örneğin kenarlar, köşeler) çıkarılmasına yardımcı olur. CNN'ler genellikle görüntü sınıflandırma, nesne tespiti ve görüntü segmentasyonunda kullanılır. CNN mimarisi ve katmanları Şekil 3.8'de verilmiştir.

Evrişimsel Sinir Ağları, 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'ndaki (ILSVRC, ImageNet Large Scale Visual Recognition Challenge) kayda değer başarılarından bu yana bilgisayarla görme görevlerinde baskın bir yöntem haline gelmiştir (Yamashita ve ark., 2018). CNN'ler görüntü tanıma, tıbbi görüntü çözünürlüğünün iyileştirilmesi ve ses kaynağı lokalizasyonu gibi çeşitli uygulamalarda büyük potansiyel göstermiştir (Wei ve ark., 2018; Zhao ve ark., 2021). Duygu analizi ve konuşma komutu tanıma gibi doğal dil işleme görevlerinde de başarıyla uygulanmışlardır (Poudel ve Ray, 2020; Hardjita ve ark., 2022). Ayrıca CNN'ler, donanım dostu mimarilerde floresan yaşam süresi görüntüleme gibi belirli alanlara uyarlanmıştır (Xiao ve ark., 2021).

CNN'lerin çok yönlülüğü, Kuantum Evrişimli Sinir Ağlarının (QCNN, Quantum Convolutional Neural Network) mevcut öğrenme modellerinin performansını artırmak için yeni bir çözüm olarak önerildiği kuantum hesaplama gibi farklı alanlara uyarlanmalarında açıkça görülmektedir (Oh ve ark., 2020). Ayrıca, CNN'ler Çin'in emlak endeksi ve hisse senedi trendlerinin tahmin edilmesinde kullanılarak finansal analizde uygulanabilirlikleri gösterilmiştir (Chen, 2023).

Ayrıca, CNN'lerin sağlamlığı ve ölçeklenebilirliği, belirli görevlerde insan performansına kolayca ulaşma ve hatta aşma yetenekleriyle vurgulanmıştır (Li ve ark., 2021). Uyarlanabilirlikleri, görüntü sınıflandırması için verimli olay güdümlü ağlara dönüştürülmeleri

ve ilaç-ilac etkileşimi çıkarımındaki uygulamaları ile daha da kanıtlanmıştır (Liu ve ark., 2016; Rueckauer ve ark., 2017).



Şekil 3.8. CNN Mimarisi ve Katmanlar

Sonuç olarak, CNN'lerin çeşitli alanlarda çok yönlü ve güçlü bir araç olduğu kanıtlanmış, bilgisayarla görme, doğal dil işleme, kuantum hesaplama, finansal analiz ve diğer birçok alandaki potansiyelleri ortaya çıkmıştır.

3.3.5. Tekrarlayan Evrişimli Sinir Ağları (Recurrent Convolutional Neural Networks - RCNN):

Tekrarlayan Evrişimli Sinir Ağları (RCNN), evrişimli sinir ağlarının ve yinelemeli sinir ağlarının özelliklerini birleştiren bir yapıya sahiptir. Genellikle zaman serisi verileri üzerinde çalışmak için kullanılır. Tekrarlayan Evrişimli Sinir Ağlarına ait mimari Şekil 3.9'da verilmiştir.


RCNN, verilerdeki uzamsal ve zamansal bağımlılıkları yakalama yetenekleri nedeniyle çeşitli alanlarda büyük ilgi görmüştür. Evrişimsel ve tekrarlayan sinir ağlarının entegrasyonu, nesne tanıma (Liang ve Hu, 2015), vücut yüzeyi potansiyel haritalama zaman serisi tanıma (Rymarczyk et al, 2022), uzay yörüngeli robotik buluşma göreceli navigasyonu için LIDAR (Laser Imaging Detection and Ranging, Işık Tespiti ve Uzaklık Tayini) odometrisi (Kechagias-Stamatis ve ark., 2020), ses olayı ve akustik sahne analizi (Tonami ve ark., 2021), otomatik modülasyon sınıflandırması (Liao ve ark., 2021) ve müzik sınıflandırması (Choi ve ark., 2017). RCNN'deki konvolüsyonel ve tekrarlayan katmanların kombinasyonu, etkili özellik çıkarma ve

dizi analizine olanak tanıyarak onu hem uzamsal hem de zamansal bilgi içeren görevler için uygun hale getirir.

RCNN, bilgisayarla görme, yapay zeka ve sinyal işleme gibi çeşitli alanlarda uygulanmıştır. Örneğin, bilgisayarla görme alanında RCNN nesne tanıma için kullanılırken (Liang ve Hu, 2015), yapay zekada müzik sınıflandırması Choi ve ark. (2017) ve otomatik modülasyon sınıflandırması (Liao ve ark., 2021) için uygulanmıştır. Ayrıca, sinyal işlemede RCNN, ses olayı tespiti Tonami ve ark. (2021) ve vücut yüzeyi potansiyel haritalama zaman serisi tanıma (Rymarczyk ve ark., 2022) için kullanılmıştır.

RCNN'nin avantajları, hem uzamsal hem de zamansal bilgileri yakalama yeteneğinden kaynaklanır ve bu da onu sıralı veriler ve uzamsal bağımlılıklar içeren görevler için uygun hale getirir. Örneğin, glikoz tahmini bağlamında, RCNN glikoz seviyelerinin zamansal dinamiklerini etkili bir şekilde yakalamak için kullanılmıştır (Li ve ark., 2018). Ayrıca, RCNN'nin metin sınıflandırma Lai ve ark. (2015) ve müzik sınıflandırma (Choi ve ark., 2017) gibi görevlerde geleneksel yöntemlerden daha iyi performans gösterdiği gösterilmiş ve sıralı verilerdeki karmaşık bağımlılıkları yakalamadaki etkinliği vurgulanmıştır.

Özetle, RCNN, evrimsel ve tekrarlayan katmanların entegrasyonu yoluyla, bilgisayarla görme, sinyal işleme ve yapay zeka dahil olmak üzere çeşitli alanlardaki uzamsal ve zamansal bağımlılıkları yakalamadaki etkinliğini göstermiştir. Özellikleri etkili bir şekilde çıkarma ve sıralı verileri analiz etme yeteneği, onu çok çeşitli uygulamalar için değerli bir araç haline getirmektedir.



Şekil 3.9. Tekrarlayan Evrişimli Sinir Ağı Mimarisi

3.3.6. Jeneratif Modeller:

Jeneratif modeller, yeni veri örnekleri üretebilen yapay sinir ağlarıdır. Örnek olarak, Üretken Karşıt Ağlar (GAN, Generative Adversarial Networks) ve Varyasyonel Otomatik Kodlayıcılar (VAE, Variational Autoencoders) gibi modeller jeneratif modellere örnektir.


GAN'ların çalışma prensibi, üretici ve ayırıcı olmak üzere iki yapay sinir ağının etkileşimine dayanır. Üretici ağı bir z gürültüsü girdisi verilir ve bu gürültüden rastgele ağırlıklarda bir resim üretir. Bu üretilen resim, gerçek resimlerin bulunduğu bir veri setindeki resimlerle karşılaştırılır.

Diğer taraftan, ayırıcı ağı, gerçek ve üretilen resimleri sınıflandırma yaparak ayırt etmeye çalışır. Ayırıcı, sahte resimlerin gerçeklik oranını tahmin eder. Bu tahmin, ayırıcının ne kadar iyi bir şekilde gerçek ve sahte resimleri ayırt edebildiğini gösterir.

Sonuçlar, maliyet fonksiyonu kullanılarak değerlendirilir. Bu fonksiyon, üretici ve ayırıcı ağların performansını ölçer ve geliştirmeler yapılması gereken alanları belirler. Performansı değerlendirildikten sonra, üretici ve ayırıcı ağların ağırlık parametreleri güncellenir. Üretken Çekişmeli Ağların çalışma prensibi Şekil 3.10'da verilmiştir.

Üretici ve ayırıcı ağlar, eş seviyelerde ilerleyerek birlikte eğitilir. Bu süreçte, her iki ağ da birbirlerini güçlendirir ve performanslarını artırmak için birlikte çalışır. Bu eş seviyeli eğitim, GAN'ların istenen sonuçları elde etmek için birlikte çalışabilme yeteneğini geliştirir (Şekil 3.10)

Tüm bu süreçlerin amacı, üretici ağın gerçekçi resimler üretebilme yeteneğini artırmak ve ayırıcı ağın gerçek ve sahte resimleri doğru bir şekilde ayırt edebilmesini sağlamaktır. GAN'lar, bu etkileşimli çalışma prensibi sayesinde yüksek kaliteli ve gerçekçi resimler üretebilme yetenekleriyle dikkat çekmektedir.



Şekil 3.10. Üretken Çekişmeli Ağların çalışma prensibi

Üretken Karşıt Ağlar, gerçekçi veri üretme yetenekleri nedeniyle çeşitli alanlarda büyük ilgi görmüştür. GAN'ların kullanımı görüntü üretimi, stil aktarımı ve düşmanca saldırılara karşı savunma gibi farklı uygulamalarda araştırılmıştır. GAN'lar için geliştirilmiş kalite, kararlılık ve varyasyonu vurgulayan yeni bir eğitim metodolojisi sunmuştur (Karras ve ark., 2017). Bu metodoloji, GAN'ların yüksek kaliteli çıktılar üretme performansını artırmaya katkıda bulunmuştur. GAN'lar için yeni mimari özellikler ve eğitim prosedürleri sunarak GAN'ların çeşitli ve gerçekçi veriler üretme yeteneklerini daha da geliştirmiştir (Salimans, 2016). Ayrıca,


mimari kısıtlamalara sahip olan ve denetimsiz öğrenme için güçlü adaylar olduğu kanıtlanan derin evrişimli GAN'lar (DCGAN, Deep Convolutional GAN) tanıtılmış ve GAN'ların uygulamaları daha da genişletilmiştir (Radford, 2015).

Ayrıca, GAN'lar mobilite ağı oluşturma (Mauro ve ark., 2022), düşman örneklere karşı savunma (Choi ve ark., 2022) ve kara kutu saldırıları için kötü amaçlı yazılım örneği oluşturma (Hu ve Ying, 2017) gibi çeşitli alanlarda uygulanmıştır. Bu uygulamalar, GAN'ların farklı alanlardaki farklı zorlukları ele alma konusundaki çok yönlülüğünü göstermektedir. Ek olarak, GAN'ların stil aktarımı ve görüntü manipülasyonunda kullanımı araştırılmış, ikna edici sahte ürünler sentezleme ve görsel çekiciliği artırma konusundaki etkinlikleri gösterilmiştir (Chen ve ark., 2019; Xiao ve ark., 2018).

Ayrıca, makine öğrenimi modellerinin düşmanca örneklere karşı sağlamlığı incelenmiş ve daha iyi modellerin düşmanca saldırılara karşı daha az savunmasız olduğunu gösteren bulgular elde edilmiştir (Wang ve ark., 2019). Bu durum, GAN'ların eksiksiz savunma çerçeveleri oluşturmak için kullanıldığı sağlam savunma mekanizmaları geliştirmenin önemini vurgulamaktadır (Sun ve ark., 2020). Ayrıca, GAN'ların eğitim sırasında ayırt edici olarak kullanılması, çıktıların gerçekçiliğini artırmak ve çeşitli uygulamalarda GAN'ların yeteneklerini daha da geliştirmek için önerilmiştir (Baluja ve Fischer, 2018).

Sonuç olarak, GAN'lar görüntü üretiminden düşman saldırılarına karşı savunmaya kadar çeşitli uygulamalarda etkinliklerini kanıtlamıştır. GAN metodolojilerindeki sürekli ilerlemeler ve çeşitli alanlardaki başarılı uygulamaları, yapay zeka ve makine öğrenimi alanındaki önemlerinin altını çizmektedir.

Varyasyonel Otomatik Kodlayıcılar'ın temeli otokodlayıcılardan gelir. Otokodlayıcı, geri yayılım yapan bir denetimsiz öğrenme algoritması olarak çalışan bir sinir ağıdır. Amacı, girdi değerini çıktıya eşitlemek için tanımlayıcı bir fonksiyon bulmaktır. Bu işlem, Şekil 3.11'de gösterilen iki farklı yapay sinir ağı olan kodlayıcı ve kod çözücü ile gerçekleştirilir. Otokodlayıcı, aslında girdi verisini iki aşamada yeniden oluşturur.



Şekil 3.11. Varyasyonel Otomatik Kodlayıcılar

Varyasyonel Otomatik Kodlayıcılar (VAE'ler), karmaşık dağılımları modelleme yetenekleri nedeniyle denetimsiz öğrenme alanında önemli bir popülerlik kazanmıştır (Doersch, 2016). VAE'ler anomali tespiti (Shu ve ark., 2022), tıbbi analizde sağkalım tahmini (Vo ve ark., 2021) ve hatta 3B geometrik nesnelerin oluşturulması (Park ve Kim, 2021) gibi çeşitli uygulamalarda kullanılmıştır. VAE'lerin derin üretken tasarım ve topoloji optimizasyonunda kullanımı da araştırılmış ve mühendislik uygulamalarındaki çok yönlülükleri gösterilmiştir (Oh ve ark., 2019; Saha ve ark., 2021). Ayrıca, VAE'ler yüksek boyutlu, sınırlı örneklemli veri sınıflandırması için denetimsiz uyarlamada umut vaat ettiğini göstermiş ve aşırı uyum ve küme analizi ile ilgili zorlukların üstesinden gelme potansiyellerini ortaya koymuştur Mahmud ve ark. (2021)

(Kingma ve Welling, 2013). VAE kavramını tanıtmış, VAE'lerin kompakt temsilleri öğrenmedeki ve örtük uzayı düzenlemedeki rolünü vurgulamıştır (Kingma ve Welling, 2013; Kingma ve Welling, 2019; Robert-George ve ark., 2021). Gizli uzayın bu şekilde düzenlenmesi, VAE'lerin aşırı uyumdan kaçınırken altta yatan veri dağılımını etkili bir şekilde yakalayabilmesini sağlamak için çok önemlidir (Tucci ve ark., 2021). Ayrıca, VAE'ler, büyük veri kümelerini işlemedeki üstünlüklerini gösteren gürültü azaltıcı oto kodlayıcılar gibi diğer oto kodlayıcı varyantlarıyla karşılaştırılmıştır (Bennouna ve ark., 2021).

VAE'lerin pratik uygulaması, moleküler üretim (Z ve ark., 2021), kalp atışı analizinde anormallik tespiti (Robert-George ve ark., 2021) ve araç yörünge tahmini (Neumeier ve ark., 2021) dahil olmak üzere çeşitli alanlarda gösterilmiştir. Ayrıca, Manyetik rezonans görüntülemelerde (MRI, Magnetic Resonance Imaging) beyin tümörü tespiti için özellik optimizasyonunda VAE'lerin kullanılması, tıbbi görüntü analizindeki potansiyellerini vurgulamaktadır (Aswani ve Menaka, 2020). VAE'lerin yorumlanabilirliği, araç yörüngelerinin tahmin edilmesinde kısmi yorumlanabilirlik sağlayan Tamamlayıcı Varyasyonel Otomatik Kodlayıcının (DVAE, Descriptive Variational Autoencoder) geliştirilmesi yoluyla da ele alınmıştır (Neumeier ve ark., 2021).

Sonuç olarak, VAE'ler denetimsiz öğrenmede güçlü bir araç olarak ortaya çıkmış ve tıbbi analizden mühendislik tasarımına kadar çeşitli alanlarda uygulanabilirliklerini göstermiştir. Kompakt temsilleri öğrenme, gizli uzayı düzenli hale getirme ve aşırı uyum ve sınırlı örneklemli veri sınıflandırmasıyla ilgili zorlukları ele alma becerileri, derin öğrenme alanındaki önemlerinin altını çizmektedir.

Bu sınıflandırmalar, yapay sinir ağlarının belirli görevlere nasıl özelleştirilebileceğini ve farklı türde veri problemleri için nasıl uyarlanabileceğini göstermektedir. Her tür, belirli bir uygulama veya probleme uygun avantajlara sahiptir.

3.4. Dalgacık Sinir Ağları (WNN, Wavelet Neural Networks)

Dalgacık sinir ağları (WNN), dalgacık teorisi ile sinir ağı teorisini bir araya getirmektedir. Bu ağlar, sinir ağı teorisinin temel prensiplerini dalgacık teorisi ile birleştirerek, daha etkili bir yapay sinir ağı modeli sunmaktadır. Bir dalgacık sinir ağı, aktivasyon fonksiyonu olarak orthonormal dalgacık ailesinden seçilmiş, tek gizli katmanlı bir ileri beslemeli sinir ağından oluşur. Bu ağlar, karmaşık veri analizi ve işleme problemleri için özellikle etkili sonuçlar sağlayabilir (Katz, 1992).

WNN, bir uygulaması olan bu orthonormal fonksiyonun tahmin edilmesi ile ilgili olarak oldukça önemli bir konudur. Bir fonksiyona ait bir dizi gözlenen değer verildiğinde, dalgacık ağı bu fonksiyonun yapısını öğrenebilme yeteneğine sahiptir ve ayrıca rastgele girişler için

beklenen deęerleri hesaplayabilir. Bu, Katz'ın (1992) alıřmasında da belirtildięi gibi gerekleřtirilebilir.


WNN, $(1 + \frac{1}{2})$ katman sinir aęı ile benzer bir yapıya sahiptir. Bu yapı, bir veya daha fazla giriři olan, tek bir gizli katmana sahip, ileri beslemeli bir aędır. Ayrıca ıkıř katmanı, bir veya daha fazla doęrusal birleřtirici veya toplayıcı ierir (řekil 3.12). Gizli katmandaki nronlar, aktivasyon fonksiyonları olarak dalgacık tabanlıdır. Bu dalgacık nronları genellikle "wavelon" olarak adlandırılır (Veitch D., 2005).

WNN, giriřlerin iřlenmesi ve ıktıların hesaplanması iin kullanılır. Bu aę, ok eřitli uygulamalarda kullanılabilir ve veri analizinde byk bir rol oynar. Dalgacık sinir aęının avantajları arasında esneklik, yksek performans ve doęrusal olmayan iliřkileri modelleme yeteneęi bulunur.

Aęın temel prensibi, giriř verilerini gizli katmandaki dalgacık nronları tarafından iřlenmesidir. Bu iřleme sreci, dalgaların birleřtirilmesi ve ıktının hesaplanmasıyla gerekleřtirilir. Dalgacık nronları, giriř verilerinin zelliklerini yakalamak ve nemli rntleri belirlemek iin kullanılır. Bu sayede, dalgacık sinir aęı karmařık veri setlerini etkili bir řekilde analiz edebilir ve ıktıları tahmin edebilir.

WNN, birok alanda kullanılan bir yapay zeka yntemidir. zellikle, grnt iřleme, sinyal iřleme, ses tanıma ve finansal analiz gibi alanlarda bařarıyla uygulanmıřtır. Bu yntem, veri analizi ve tahminlemeye ynelik birok sorunu zmek iin kullanılabilir.

WNN'nin gelecekteki potansiyeli olduka yksektir. Yeniliki arařtırmalar ve geliřtirmeler, bu yntemin daha da iyileřtirilmesini ve geniřletilmesini saęlayabilir. Bu nedenle, dalgacık sinir aęı, yapay zeka alanındaki ilerlemelerin bir parası olarak nemli bir rol oynamaya devam edecektir.



Şekil 3.12. Dalgacık sinir ağı yapısı.

WNN'yi oluşturmak için iki temel yaklaşım vardır.

- İlkinde dalgacık ve sinir ağı işlemleri ayrı ayrı gerçekleştirilir. İlk olarak, giriş sinyali, gizli katmandaki dalgacık tabanlı nöronlar kullanılarak ayrıştırılır. Ardından, öğrenme algoritmasına uygun olarak giriş ağırlıkları değiştirilen bir ya da daha fazla toplayıcıdan dalgacık katsayıları çıkış olarak verilir. Bu süreç, dalgacık ve sinir ağlarının etkileşimini içerir ve verilerin daha iyi bir şekilde işlenmesini sağlar. Ayrıca, dalgacık tabanlı nöronlar sayesinde daha karmaşık örüntülerin tanınması ve analizi de mümkün hale gelir.
- İkincisinde ise iki teori bir araya getirilir. Bu durumda; dalgacıkların öteleme ve genişlemesi, toplayıcı ağırlıkları ile birlikte, bazı öğrenme algoritmalarına uygun olarak, değiştirilir. Ayrıca, bu değişikliklerin sonucunda, sistemdeki performansın artması beklenir. Örneğin, dalgacıkların öteleme ve genişlemesi, toplayıcı ağırlıkları ile birlikte optimize edilebilir ve böylece daha etkili bir öğrenme süreci sağlanabilir. Bunun yanı sıra, bu değişikliklerin, sistemdeki hataları azaltması ve daha doğru sonuçlar elde edilmesini sağlaması hedeflenir. Bu sayede, öğrenme algoritmalarının daha güçlü ve verimli bir şekilde çalışması sağlanır.

Genel olarak, ilk yaklaşım kullanıldığında, sadece ana dalgacığın ikili genişlemesi ve ötelemesi dalgacık temelini oluşturmaktadır. Bu tip dalgacık sinir ağları genellikle "wavenet" olarak anılmaktadır. İkinci tip yapı ise "dalgacık ağı" olarak adlandırılmaktadır (Veitch D., 2005).

Bu yaklaşımın kullanılması, dalgacıkların karmaşık özelliklerini daha iyi anlamamıza ve daha etkili sonuçlar elde etmemize yardımcı olabilir. Örneğin, WNN, ses sentezinde veya müzik oluşturmada kullanıldığında daha gerçekçi ve doğal sonuçlar verebilir. Ayrıca, WNN yapısı, veri sıkıştırma veya görüntü işleme gibi alanlarda da kullanılabilir. Bu sayede, daha fazla veri işleme ve analiz yapabiliriz.

Veitch'in çalışması, dalgacık sinir ağlarının kullanımının farklı alanlarda nasıl uygulanabileceğini ve potansiyel faydalarını göstermektedir. Bu nedenle, WNN konseptini daha iyi anlamak ve uygulamalarını araştırmak önemlidir. Gelecekte, dalgacık sinir ağları ve dalgacık ağı yapısı, daha da geliştirilerek daha geniş bir kullanım alanına sahip olabilir.


3.4.1. Tek boyutlu dalgacık sinir ağı

Tek boyutlu dalgacık sinir ağı, bir giriş ile bir çıkıştan oluşan en basit formda bulunur. Bununla birlikte, daha fazla ayrıntı eklemek için gizli katman kullanılabilir. Gizli katmanda, giriş parametreleri (muhtemelen sabittir) dalgacığın öteleme ve genişleme katsayılarını içeren dalgacık nöronları bulunur. Bu dalgacık nöronları, girişlerin küçük bir alan içinde kalması durumunda sıfırdan farklı bir çıkış üretir. Bu şekilde, dalgacık sinir ağının çıkışı, dalgacık aktivasyon fonksiyonlarının ağırlıklı doğrusal bileşimidir. Bu yapı, daha karmaşık problemleri çözebilmek için kullanılabilir ve daha fazla esneklik sağlar.

Şekil 3.13'de tek çıkışlı dalgacık nöronun yapısı gösterilmektedir. Çıkış;

$$\psi_{\lambda,t}(u) = \psi\left(\frac{u-t}{\lambda}\right) \quad (3.1)$$

Şeklinde ifade edilir. λ ve t sırasıyla öteleme ve genişleme parametreleridir.



Şekil 3.13. Dalgacık nöronu.

3.4.1.1. Dalgacık ağı

Tek giriş tek çıkış dalgacık ağı mimarisi Şekil 3.14'te gösterilmiştir. Gizli katman M adet dalgacık nöronu içerir. Çıkış nöronu bir toplayıcıdır ve dalgacık nöronlarının çıkışlarının ağırlıklı toplamını çıkış olarak verir.


$$y(u) = \sum_{i=1}^M w_i \psi_{\lambda_i, t_i}(u) + \bar{y} \quad (3.2)$$

$\bar{y}$ değerinin eklenmesinin sebebi, dalgacık fonksiyonu $\psi(u)$ sıfır ortalamalı olduğu sürece, ortalaması sıfırdan farklı fonksiyonlarla başa çıkmak içindir. $\bar{y}$, ölçekleme fonksiyonu için bir yer değiştirme değeridir.

Bir dalgacık ağı ait tüm parametreler bazı öğrenme algoritmaları ile ayarlanabilir (Veitch D., 2005).

3.4.1.2. Wavenet

Wavenet mimarisi dalgacık ağı ile aynıdır fakat t_i ve λ_i parametreleri başlangıçta sabittir ve herhangi bir öğrenme prosedürü ile değişmez (Veitch D., 2005).



Şekil 3.14. Dalgacık sinir ağı.

Bu kısıtlamanın ana sebeplerinden biri dalgacık analizinden gelmektedir. Yani, aşağıda verilen herhangi bir $f(\cdot)$ fonksiyonu için yeterince büyük bir L değeri seçilerek keyfi bir ayrıştırma seviyesine yaklaştırılabilir.

$$f(u) \approx \sum_k \langle f, \varphi_{L,k} \rangle \varphi_{L,k}(u) \quad (3.3)$$

burada $\varphi_{L,k}(u) = 2^{L/2} \varphi(2^L u - k)$ ölçekleme fonksiyonu 2^L ile genişletilmiş ve 2^{-L} ikili aralığı ile ötelenmiştir.

Bu nedenle wavenet'in çıkışı;

$$y(u) = \sum_{i=1}^M w_i \varphi_{\lambda_i, t_i}(u) \quad (3.4)$$

şeklinde olacaktır. Burada M , analiz edilecek fonksiyonun kümesini kapsayacak derecede büyük olmalıdır. Şunu da eklemek gerekir ki, ölçekleme fonksiyonunun ortalama değeri sıfırdan farklı olduğu sürece düzeltme değeri olan $\bar{y}$ değerine ihtiyaç olmayacaktır (Veitch D., 2005).


3.4.2. Çok boyutlu dalgacık sinir ağı

Bu tip dalgacık sinir ağında, giriş çok boyutlu bir vektördür ve dalgacık nöronları çok boyutlu aktivasyon fonksiyonları içermektedir. Giriş vektörü, çok boyutlu giriş uzayının küçük bir alanında kaldığı sürece, dalgacık nöronları sıfırdan farklı bir çıkış üretir. Dalgacık sinir ağının çıkışı, bu çok boyutlu dalgacıkların bir tanesinin veya daha fazlasının doğrusal bileşiminden oluşur (Veitch D., 2005).

Şekil 3.15'te çok boyutlu dalgacık sinir ağı için dalgacık nöronun yapısı gösterilmiştir. Çıkış;

$$\psi(u_1, \dots, u_N) = \prod_{n=1}^N \psi_{\lambda_n, t_n}(u_n) \quad (3.5)$$

şeklinde ifade edilir (Seifollahi ve ark.,2021). Bu dalgacık nöronun etkisi, çok boyutlu bir dalgacığa eşdeğerdir.



Şekil 3.15. Çok boyutlu dalgacık aktivasyon fonksiyonlu dalgacık nöronu.

Çok boyutlu dalgacık sinir ağının mimarisi Şekil 3.15’de gösterilmiştir. Gizli katman M adet dalgacık nöronu, çıkış katmanı ise K adet toplayıcı içerir. Ağın çıkışı aşağıdaki gibi ifade edilir.

$$y_j = \sum_{i=1}^M w_{ij} \psi_i(u_1, \dots, u_N) + \bar{y}_j \quad (j = 1, \dots, K) \quad (3.6)$$


Burada, $\bar{y}_i$ değerine, ortalaması sınırdan farklı fonksiyonlarla başa çıkabilmek için ihtiyaç duyulmaktadır.

Dolayısıyla, ağın giriş – çıkış ifadesi aşağıdaki gibi tanımlanabilir;

$$y(u) = \sum_{i=1}^M w_i \psi_i(u) + \bar{y} \quad \text{burada} \quad \begin{cases} y = (y_1, \dots, y_K) \\ w_i = (w_{i1}, \dots, w_{iK}) \\ u = (u_1, \dots, u_N) \\ \bar{y} = (\bar{y}_1, \dots, \bar{y}_K) \end{cases} \quad (3.7)$$

3.5. Hibrit Model İşlem Adımları

Tez çalışmamızda oluşturmak istediğimiz hibrit modelin işlem adımları Şekil 3.16’da verilmiştir.



Şekil 3.16. Hibrit Model Algoritması

- Atmosferik zaman verileri için 2020 yılına ait 10 dakika çözünürlüklü basınç, sıcaklık ve nem verileri kullanılmıştır. Her ayın ilk gününe ait 24 saate karşılık gelen her bir atmosferik veri için 144 veri noktasından oluşan veri setleri oluşturulmuştur.
- Veriler ayrıştırma ve tahminleme işlemi öncesinde normalizasyon işlemine tabi tutulmuştur.
- Birincil ayrıştırma işlemine tabi tutulan verilerden içsel mod fonksiyonları elde edilecek şekilde ayrıştırılmıştır.
- İlk içsel mod fonksiyonları, içsel mod fonksiyonları arasında en düzensiz ve sistematik olmayan kısımlar olması sebebiyle tahmin zorluğunu artırmaktadır. Bu etkiyi azaltmak için 1. içsel mod fonksiyonları ikincil ayrıştırma işlemine tabi tutulmuştur.
- Birincil ve ikincil ayrıştırma sonrasında elde edilen içsel mod fonksiyonları tekrar normalizasyon işlemine tabi tutularak veri boyutlandırması düzenlenmiştir.
- İkincil ayrıştırma sonucu elde edilen veri setlerinden ilk 6 zaman noktasına ait basınç, sıcaklık ile nem verisi (00:00-00:50) zaman aralığı ve 01:00 saatine ait rüzgar hızı verisi sinir ağını eğitmek için kullanılmıştır. Ardından zaman serisi verisi 1 adım ileri kaydırılarak (00:10-01:00) sinir ağı girişi olarak kullanılarak 01:10 zaman noktasına ait rüzgar hızı tahmin edilmeye çalışılmıştır. Bu işlem her döngüye 1 adım ileri kaydırılarak 144 adet (24 saatlik) veri tahminlenene kadar sürdürülmüştür. Yapılan işlem Şekil 3.17’de gösterilmiştir.

- **Girdi Verisi:** İlk 6 zaman noktasına ait basınç, sıcaklık ve nem verisi
- **Kaydırma İşlemi:** 1 adım ileri kaydırarak sonraki zaman noktasını tahmin etme

Eğitim ve Tahmin Süreci:

Adım	Girdi Zaman Aralığı	Hedef Zaman Noktası	Hedef Rüzgar Hızı
1	00:00 - 00:50	01:00	?
2	00:10 - 01:00	01:10	?
...	...	...	...
144	23:00 - 23:50	00:00 (Sonraki Gün)	?

Şekil 3.17. Sinir ağı eğitim ve tahmin süreci

Veri ayrıştırma yöntemleri bölümünde bahsi geçen yöntemlerden dört tanesi ile ikili kombinasyonlar oluşturularak, Tablo 3.2’de verilen ikili ayrıştırma yapıları oluşturulmuştur.

Tablo 3.2. Veri ayrıştırma model listesi

VERİ AYRIŞTIRMA MODELİ	BİRİNCİL VERİ AYRIŞTIRMA YÖNTEMİ	İKİNCİL VERİ AYRIŞTIRMA YÖNTEMİ
MODEL 1	CEEMDAN	CEEMDAN
MODEL 2	CEEMDAN	EEMD
MODEL 3	CEEMDAN	LMD
MODEL 4	CEEMDAN	VMD
MODEL 5	EEMD	CEEMDAN
MODEL 6	EEMD	EEMD
MODEL 7	EEMD	LMD
MODEL 8	EEMD	VMD
MODEL 9	LMD	CEEMDAN
MODEL 10	LMD	EEMD
MODEL 11	LMD	LMD
MODEL 12	LMD	VMD
MODEL 13	VMD	CEEMDAN
MODEL 14	VMD	EEMD
MODEL 15	VMD	LMD
MODEL 16	VMD	VMD

3.5.1. Normalizasyon

Yapay sinir ağlarında, ağ giriş ve çıkışlarına belirli ön işlem adımları uygulayarak yapay sinir ağına sunulan verilerin eğitimi daha verimli hale getirilebilir. Ağ giriş işlem fonksiyonları, ağ kullanımını daha iyi bir forma dönüştürür. Normalleştirme işlemi ham verilere uygulanarak ve bu verilerin eğitim için uygun veri setinin hazırlanmasına etkisi vardır. Yapay sinir ağların eğitimi, ham veri setine normalizasyon yöntemi uygulanmadan çok yavaş olabilir.

Normalleştirme işlemlerinde farklı teknikler kullanılabilir. Literatürde birçok veri normalizasyon çeşidi vardır. Bunlar; Min kuralı, Max kuralı, Medyan, Sigmoid ve Z-Score gibi kurallar olarak sıralanabilir (Jayalakshmi ve Santhakumaran , 2011).

Seçilen modelin girdi ve çıktıların ölçeklendirilmesi (normalizasyon) ağı başarımını yakından etkilemektedir. Çünkü normalizasyon, veri setindeki değerlerin dağılımını düzenli hale getirmektedir. YSA girdileri arasında aşırı büyük veya küçük değerler görülebilir. Bunlar yanlışlıkla girdi setine girmiş olabilir. Net girdiler hesaplanırken bu değerler aşırı büyük veya küçük değerlerin doğmasına neden olarak ağı yanlış yönlendirebilirler. Bütün girdilerin belirli aralıkta (çoğunlukla 0-1 aralığında) ölçeklendirilmesi hem farklı ortamlardan gelen bilgilerin aynı ölçek üzerine indirgenmesine hem de yanlış girilen çok büyük ve küçük şeklindeki değerlerin etkisinin ortadan kalkmasına neden olur. Bazı araştırmacılar ise kendi problemlerine özgü ölçeklendirme yöntemleri geliştirmektedir. Her problem için farklı bir ölçeklendirme yöntemi kullanılabilir. Tasarımcılar, ellerindeki verileri normalize edecek bir yaklaşımı kendileri belirleyebilir. Bu konuda bir standart koymak doğru olmayacaktır (Öztemel, 2003). Bu çalışmada hazırlanan basınç, sıcaklık, nem ve rüzgar hızı verilerinin normalizasyonu için farklı teknikler üzerinde denemeler yapılmış ve en başarılı sonuçlar D_Min_Max Normalizasyonu tekniğinde ortaya çıkmıştır. Normalizasyon yapılarak veriler boyutsuz hale getirilmiştir (Doğan ve ark., 2007). Bu yöntem için aşağıdaki eşitlik kullanılır.

$$x' = 0,8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0,1 \quad (3.8)$$

Bu eşitlikte;

x'; Normalize edilmiş veriyi,

x_i; Girdi değerini,

x_{min}; Girdi seti içerisinde yer alan en küçük sayıyı,

x_{max}; Girdi seti içerisinde yer alan en büyük sayıyı, ifade etmektedir.

İkili ayrıştırma için oluşturulmuş olan 16 adet modele giriş verisini sağlayacak olan basınç, sıcaklık ve nem verileri, yukarıda verilen denklem ile 0,1 ile 0,9 arasında normalize edilerek ayrıştırma işlemine tabi tutulmuştur.

3.5.2. Sinir Ağı Mimarisinin Belirlenmesi

Tokat Gaziosmanpaşa Üniversitesi Taşlıçiftlik Kampüsü yerleşkesine konuşlandırılan ölçüm istasyonundan alınan 10 dakika aralıklı sıcaklık, nem, basınç ve 40 m yükseklikteki hız verileri kullanılarak öncelikli olarak çok kısa vadeli rüzgar hızı tahmini yapılmaya çalışılmıştır.

Seçilen mimari basınç, sıcaklık ve nem için birer giriş, rüzgar hızı için bir çıkış olacak şekilde bir girdi katmanı, bir çıktı katmanı ve bir gizli katmanlı ağ yapısı şeklindedir. Gizli katmandaki nöron sayısı ile ilgili hesaplamalarda literatürde birden fazla yöntemin olduğu ve tam olarak kaç olması gerektiğine ilişkin belirli bir kural olmadığı görülmektedir (Baily ve Thomson, 1990). Bir girdi katmanı, bir gizli katman ve bir çıktı katmanından oluşan üç katmanlı bir YSA için, gizli nöron sayısının, girdi katmanındaki nöron sayısının %75'i olması gerektiğini ileri sürmüştür. Katz(1992), en uygun gizli nöron sayısının, giriş katmanındaki nöron sayısının 1,5 katı ile 3 katı arasında olduğunu ileri sürmektedir. Doig (1999)'e göre ise gizli katmanda olması gereken nöron sayısının gizli katman sayısına göre çok daha fazla alternatife sahip olduğundan uygun sayıyı belirlemek üzere aşağıdaki formülden yararlanılabileceğini söylemiştir.

$$N_s = \frac{\frac{1}{2}(N_g + N_c) + \sqrt{N_d}}{N_b} \quad (3.9)$$

N_s : Gizli katmandaki nöron sayısını

N_g : Girdi katmanındaki nöron sayısını

N_c : Çıktı katmanındaki nöron sayısını

N_d : Gözlem sayısını

N_b : Katman sayısını göstermektedir.

Bu formüle göre çalışmada oluşturulan yapay sinir ağı modellerinde 40 m yükseklikteki rüzgar hızı tahmin eden model için 144 gözlem sayısı için bir gizli katmandaki nöron sayısı 14 olarak hesaplanmıştır.

Gizli katmandaki nöron sayısı öncelikle 14 olarak denenmiştir ve daha sonra sayı azaltıp artırılarak tahmin sonuçları birbirleriyle kıyaslanmıştır. En iyi tahmin sonuçlarının 10 gizli nöron sayısına sahip modelde olduğu görülmüştür. Böylelikle bir girdi katmanı, bir çıktı

katmanı ve bir gizli katmanlı ağ yapısı için tüm modellerde 10 nöron ya da 10 dalgacık nöronu kullanılmıştır.

3.5.3. Sinir Ağlarının Eğitilmesi

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması gradyen azalması algoritmasıdır. Bu algortmada ağırlıklar, performans fonksiyonunun azalması yönünde ayarlanır. Fakat bu yöntem, pek çok problem için çok yavaş kalmaktadır. Bu algortmadan daha hızlı, daha yüksek performanslı algortmalar da vardır.

Hızlı algortmalar genel olarak iki kategoriye ayrılabilir. İlk kategorideki algortmalar, deneme yanılma tekniklerini kullanarak, standart gradyen azalması (steepest descent) yönteminden daha iyi sonuçlar verebilir. Deneme-yanılma işlemlerini kullanan geriye yayılım algortmaları; momentum terimli geriye yayılım, öğrenme hızı değişen geriye yayılım ve esnek geriye yayılım algortmalarıdır. Hızlı algortmaların ikinci kategorisindeki algortmalar, standart sayısal optimizasyon yöntemlerini kullanır. Bu algortmalar; eşlenik gradyen öğrenme algortması, Newton öğrenme algortmaları ve Levenberg - Marquardt öğrenme algortmasıdır.

Öğrenme algortmaları, kendisinden önce geliştirilen algortmalara alternatif olarak ortaya çıkmıştır ve önceki algortmaların iyi yönlerini geliştirip, kötü yönlerini azaltmaya yönelmiştir. Levenberg - Marquardt algortması da, Newton ve Gradyen Azalması algortmalarının en iyi özelliklerinden oluşur ve kısıtlamalarını ortadan kaldırır (Bolat ve Kalenderli, 2003).

Seçilen ağ mimarisinde ileri beslemeli yapay sinir ağına ait nöronların eğitilmesi için Levenberg-Marquardt algortması tercih edilmiştir. Geriye yayılım algortması, yapay sinir ağlarında en çok kullanılan algortmadır. Geriye yayılım öğrenmesi sırasında ağ, her giriş örüntüsünü, çıkış nöronlarında sonuç üretmek üzere gizli katmanlardaki nöronlardan geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuçla, elde edilen sonuç karşılaştırılır. Bundan sonra, çıkış hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçirilir. Hata değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için


ağırlıklarını ayarlar. Ağırlık değiştirme denklemleri, ağıdaki performans fonksiyonunu en küçük yapacak şekilde düzenlenir.

3.5.4. YSA Aktivasyon Fonksiyonları

YSA yapılarında en sık kullanılan aktivasyon fonksiyonlardan biri, Şekil 3.18a'da gösterilen Log-sigmoid transfer fonksiyonudur (LOGSIG). Bu transfer fonksiyonu, girdiyi (artı ve eksi sonsuz arasında herhangi bir değere sahip olabilir) alır ve çıktığı 0 ile 1 aralığına sıkıştırır. Log-sigmoid transfer işlevi, kısmen bu işlevin türevlenebilir olması nedeniyle, geri yayılım algoritması kullanılarak eğitilmiş çok katmanlı ağlarda yaygın olarak kullanılır.

Sinir ağları terminolojisinde hiperbolik tanjant transfer fonksiyonu (TANSIG, Şekil 3.18b), -1 ile +1 aralığında bir çıkışı olan iki kutuplu bir sigmoid ile ilgilidir. Bu aktivasyon matematiksel olarak $\tanh(n)$ fonksiyonuna eşdeğerdir. Tanh'den daha hızlı çalışması bakımından farklıdır, ancak sonuçlar çok küçük sayısal farklılıklara sahip olabilir. Bu fonksiyon, hızın şekilden daha önemli olduğu sinir ağları için tercih edilen bir transfer fonksiyonudur.

Çoğu gerçek model, doğrusal olmayan giriş/çıkış özelliklerine sahiptir. Ancak bazı modeller, nominal parametreler içinde çalıştırıldığında (aşırı tahrikli değil) doğrusala yeterince yakın bir davranışa sahiptir. Purelin Transfer işlevi (Şekil 3.18c), bu tür durumlarda giriş/çıkış davranışının kabul edilebilir bir temsili olabilir.



Şekil 3.18. (a) Log-Sigmoid Transfer Fonksiyonu (b) Tan-Sigmoid Transfer Fonksiyonu (c) Purelin Transfer Fonksiyonu

3.5.5. DSA Aktivasyon Fonksiyonları

Tablo 3.3'te Dalgacık Sinir Ağı oluşturmak için seçilen 13 adet dalgacık fonksiyonlarının listesi verilmiştir (Othmani ve ark., 2012; Seifollahi ve ark.,2021)

Tablo 3.3. Dalgacık Aktivasyon Fonksiyonları

Fonksiyon Adı	Matematiksel Formülü
Mexican Hat	$f(x) = \left(\frac{2}{\sqrt{3}}\pi^{1/4}\right) e^{-\frac{x^2}{2}}(1 - x^2)$
Morlet	$f(x) = e^{-(x^2)/2} * \cos(5 * x)$
Polywog1	$f(x) = x * e^{-\frac{x^2}{2}}$
Polywog2	$f(x) = e^{-\frac{x^2}{2}}(-3x + x^3)$
Polywog3	$f(x) = e^{-\frac{x^2}{2}}(3 - 6x^2 + x^4)$
Polywog4	$f(x) = e^{-\frac{x^2}{2}}(1 - x^2)$
Polywog5	$f(x) = e^{-\frac{x^2}{2}}(3x^2 - x^4)$
Rasp1	$f(x) = \frac{x}{(1 + x^2)^2}$
Rasp2	$f(x) = \frac{x\cos[x]}{1 + x^2}$
Rasp3	$f(x) = \frac{\sin\pi x}{-1 + x^2}$
Shannon	$f(x) = ((\sin 2\pi x) - \sin(\pi x))/(\pi x)$
Slog1	$f(x) = -\frac{1}{1 + e^{-3-x}} + \frac{1}{1 + e^{-1-x}} + \frac{1}{1 + e^{1-x}} - \frac{1}{1 + e^{3-x}}$
Slog2	$f(x) = -\frac{1}{1 + e^{-3-x}} + \frac{3}{1 + e^{-1-x}} - \frac{3}{1 + e^{1-x}} + \frac{1}{1 + e^{3-x}}$

Dalgacık Sinir Ağı mimarisinde, bir önceki dönemde kullanılmış olan Yapay Sinir Ağı mimarisinin aynısı kullanılmıştır. DSA yine YSA'nın öğrenme algoritması ile eğitilmiştir. Klasik YSA aktivasyon fonksiyonları yerine Tablo 3.3'te verilen 13 adet dalgacık aktivasyon fonksiyonu kullanılmıştır. 16 adet ikili ayrıştırma modeli ile YSA ve DSA'nın toplam 16 aktivasyon fonksiyonu çapraz eşleştirilerek 256 ayrı hibrit model oluşturulmuştur.

3.5.6. Hibrit Modellerin Başarımı

İkincil ayrıştırmalı – YSA/DSA tabanlı modellerin başarımının ölçümü için kullanılan birinci ölçü, (3.10) eşitliği ile verilen toplam karesel hatanın ortalaması alınarak aşağıdaki gibi hesaplanır (Ortalama Karesel Hata, Mean Squared Error, MSE)). Hata kareleri ortalaması sayısal kestirimler için en çok kullanılan başarı ölçülerinden biridir. Bu değer, her hesaplanan değer ve onun karşılık gelen doğru değer arasındaki farkın karelerinin ortalaması alınarak hesaplanır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\varepsilon_i)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (3.10)$$

Model başarımının ölçümü için kullanılan ikinci ölçü (3.11) eşitliği ile verilen ortalama karesel hatanın karekökünün alınması suretiyle belirlenen hatadır (Kök Ortalama Kare Hatası, Root Mean Squared Error, RMSE). RMSE model veya kestirimci tarafından kestirimi yapılan değerler ve modellenen veya kestirimi yapılandan elde edilen gerçek değerler arasındaki farkın ölçüsü olarak sıklıkla kullanılır (Challagulla ve ark, 2005).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\varepsilon_i)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (3.11)$$

RMSE basitçe MSE'nin kareköküdür. RMSE hata değerini gerçek ve kestirilen değerdeki gibi aynı boyutta verir.

4. BULGULAR VE TARTIŞMA

4.1. Bulgular

Yaptığımız çalışmanın ilk edabında, 16 adet ikili ayrıştırma modeli ve 16 adet aktivasyon fonksiyonu (3 adet klasik YSA+13 adet DSA aktivasyon fonksiyonu) ile oluşturulmuş olan 256 hibrit model için 1 Ocak 2020 tarihi için yapılan 10 dakika çözünürlüklü 24 saatlik rüzgar hızı tahminlemesi yapılmıştır. Bir sonraki adımda, oluşturmuş olduğumuz 256 hibrit modelin mevsim değişiklikleri sebebiyle oluşacak farklı atmosferik koşullardaki tepkilerini belirleyebilmek için üç farklı ay daha seçilerek simülasyonlar yapılmıştır. Öncelikli olarak model simülasyonları yapılacak aylar, mevsimlerin ortasına gelecek şekilde seçilerek, mevsimsel şartların stabilize olmasını garanti edilmiştir. İlk olarak gerçekleştirmiş olduğumuz 1 Ocak 2020 simülasyonları kış mevsimine referans olacak şekilde, ilkbahar için 1 Nisan 2020, yaz için 1 Temmuz 2020 ve sonbahar için 1 Ekim 2020 tarihlerine ait veriler ile 256 hibrit model test edilmiştir.

Çalışmamızın ikinci safhasında hibrit modellerin tepkilerini tüm yıl da görebilmek için mevsimlere ait simülasyon sonuçlarını baz alarak hem ayrıştırma modellerinin sayılarında hem de aktivasyon fonksiyonlarının sayılarında indirgemeye gidilerek hibrit model sayısı azaltmıştır.

Hibrit model sayısının belirlenmesinde; 4 farklı mevsime ait 256 hibrit modelin, MSE ve RMSE sonuçları incelenerek en düşük hata ortalamalarına ait 2 tanesi Yapay Sinir Ağı (YSA), 6 tanesi Dalgacık Sinir Ağı (DSA) aktivasyon fonksiyonu olacak şekilde toplam aktivasyon fonksiyonu sayısı 8'e indirgenmişti.

Benzer şekilde ikili ayrıştırma modellerinin sayısı da; 256 hibrit modelin, MSE ve RMSE sonuçları incelenerek en düşük hata ortalamalarına sahip her mevsimsel sonuçtaki en iyi 8'er ayrıştırma modeli sıralanarak, 4 mevsim bazlı simülasyonun en az %75'inde ilk 8'e girebilmiş 6 adet ayrıştırma modeli seçilmiştir. (Tablo 4.9)

Tablo 4.1. Ocak ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0.0131	0.0080	0.0289	0.0128	0.0078	0.0060	0.0206	0.0410	0.0072	0.0102	0.0058	0.0067	0.0201	0.0151	0.0058	0.0061
CEEMDAN+EEMD	0.0155	0.0052	0.0369	0.0110	0.0061	0.0065	0.0167	0.0594	0.0085	0.0126	0.0050	0.0079	0.0214	0.0134	0.0043	0.0065
CEEMDAN+LMD	0.0089	0.0112	0.0733	0.0153	0.0049	0.0075	0.0178	0.0530	0.0095	0.0167	0.0096	0.0068	0.0181	0.0120	0.0062	0.0050
CEEMDAN+VMD	0.0129	0.0063	0.0265	0.0128	0.0068	0.0071	0.0131	0.0343	0.0089	0.0151	0.0070	0.0065	0.0229	0.0121	0.0046	0.0037
EEMD+CEEMDAN	0.0123	0.0085	0.0242	0.0102	0.0058	0.0045	0.0129	0.0444	0.0089	0.0158	0.0079	0.0073	0.0239	0.0176	0.0048	0.0043
EEMD+EEMD	0.0121	0.0075	0.1443	0.0087	0.0071	0.0064	0.0101	0.0440	0.0092	0.0144	0.0052	0.0069	0.0103	0.0102	0.0056	0.0067
EEMD+LMD	0.0142	0.0055	0.0197	0.0164	0.0074	0.0074	0.0123	0.0532	0.0169	0.0084	0.0070	0.0074	0.0199	0.0166	0.0057	0.0040
EEMD+VMD	0.0119	0.0063	0.0299	0.0087	0.0080	0.0059	0.0152	0.0335	0.0115	0.0145	0.0072	0.0080	0.0224	0.0109	0.0040	0.0038
LMD+CEEMDAN	0.0091	0.0107	0.0160	0.0096	0.0053	0.0055	0.0199	0.0503	0.0090	0.0078	0.0051	0.0059	0.0263	0.0068	0.0055	0.0057
LMD+EEMD	0.0127	0.0088	0.0134	0.0126	0.0074	0.0072	0.0127	0.0483	0.0121	0.0168	0.0068	0.0064	0.0190	0.0068	0.0047	0.0047
LMD+LMD	0.0121	0.0078	0.0282	0.0114	0.0064	0.0101	0.0153	0.0381	0.0115	0.0116	0.0069	0.0058	0.0185	0.0104	0.0045	0.0044
LMD+VMD	0.0115	0.0071	0.0232	0.0147	0.0069	0.0075	0.0082	0.0351	0.0072	0.0151	0.0064	0.0066	0.0194	0.0125	0.0049	0.0060
VMD+CEEMDAN	0.0154	0.0070	0.0167	0.0156	0.0075	0.0049	0.0132	0.0605	0.0088	0.0158	0.0057	0.0061	0.0172	0.0079	0.0059	0.0045
VMD+EEMD	0.0160	0.0052	0.0270	0.0120	0.0065	0.0075	0.0094	0.0496	0.0091	0.0116	0.0042	0.0068	0.0228	0.0123	0.0045	0.0052
VMD+LMD	0.0178	0.0052	0.0338	0.0137	0.0058	0.0070	0.0126	0.0535	0.0060	0.0106	0.0079	0.0079	0.0205	0.0152	0.0054	0.0048
VMD+VMD	0.0080	0.0052	0.0214	0.0144	0.0078	0.0059	0.0158	0.0464	0.0091	0.0117	0.0058	0.0081	0.0185	0.0134	0.0055	0.0063

(Renklendirme; her bir ayırıştırma tekniği için aktivasyon fonksiyonlarının en iyi MSE değeri yeşil, en kötü MSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.2. Ocak ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,1147	0,0895	0,1699	0,1132	0,0882	0,0773	0,1434	0,2025	0,0847	0,1010	0,0763	0,0817	0,1417	0,1229	0,0763	0,0780
CEEMDAN+EEMD	0,1247	0,0718	0,1921	0,1048	0,0780	0,0808	0,1291	0,2437	0,0921	0,1121	0,0708	0,0888	0,1462	0,1157	0,0652	0,0805
CEEMDAN+LMD	0,0944	0,1060	0,2707	0,1238	0,0699	0,0865	0,1335	0,2302	0,0972	0,1291	0,0979	0,0825	0,1347	0,1093	0,0789	0,0704
CEEMDAN+VMD	0,1136	0,0792	0,1626	0,1129	0,0826	0,0843	0,1146	0,1852	0,0941	0,1228	0,0838	0,0809	0,1512	0,1099	0,0682	0,0610
EEMD+CEEMDAN	0,1109	0,0924	0,1554	0,1010	0,0760	0,0669	0,1134	0,2108	0,0944	0,1259	0,0889	0,0852	0,1547	0,1327	0,0696	0,0656
EEMD+EEMD	0,1101	0,0867	0,3799	0,0935	0,0842	0,0803	0,1005	0,2097	0,0961	0,1199	0,0720	0,0829	0,1016	0,1012	0,0748	0,0816
EEMD+LMD	0,1193	0,0743	0,1404	0,1282	0,0860	0,0858	0,1107	0,2305	0,1301	0,0916	0,0835	0,0862	0,1410	0,1287	0,0752	0,0629
EEMD+VMD	0,1093	0,0792	0,1728	0,0934	0,0892	0,0768	0,1234	0,1831	0,1072	0,1205	0,0850	0,0894	0,1496	0,1044	0,0631	0,0616
LMD+CEEMDAN	0,0956	0,1033	0,1263	0,0979	0,0725	0,0739	0,1411	0,2244	0,0951	0,0880	0,0713	0,0770	0,1622	0,0822	0,0741	0,0758
LMD+EEMD	0,1126	0,0938	0,1159	0,1123	0,0859	0,0850	0,1128	0,2198	0,1098	0,1297	0,0825	0,0803	0,1377	0,1090	0,0686	0,0685
LMD+LMD	0,1102	0,0885	0,1680	0,1068	0,0800	0,1003	0,1236	0,1951	0,1073	0,1078	0,0829	0,0762	0,1359	0,1022	0,0672	0,0662
LMD+VMD	0,1073	0,0843	0,1524	0,1213	0,0829	0,0867	0,0906	0,1874	0,0847	0,1231	0,0798	0,0813	0,1394	0,1117	0,0703	0,0776
VMD+CEEMDAN	0,1241	0,0838	0,1294	0,1251	0,0868	0,0702	0,1149	0,2460	0,0940	0,1255	0,0753	0,0780	0,1313	0,0888	0,0768	0,0670
VMD+EEMD	0,1264	0,0721	0,1643	0,1096	0,0807	0,0866	0,0970	0,2226	0,0956	0,1077	0,0649	0,0827	0,1511	0,1109	0,0673	0,0721
VMD+LMD	0,1334	0,0786	0,1839	0,1171	0,0762	0,0837	0,1121	0,2313	0,0771	0,1031	0,0888	0,0886	0,1433	0,1234	0,0732	0,0695
VMD+VMD	0,0894	0,0758	0,1463	0,1200	0,0883	0,0771	0,1256	0,2155	0,0953	0,1082	0,0760	0,0901	0,1360	0,1159	0,0741	0,0796

(Renklendirme; her bir ayırıştırma tekniği için aktivasyon fonksiyonlarının en iyi RMSE değeri yeşil, en kötü RMSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.3. Nisan ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,0273	0,0115	0,0310	0,0163	0,0163	0,0102	0,0197	0,0677	0,0177	0,0141	0,0129	0,0084	0,0368	0,0187	0,0070	0,0084
CEEMDAN+EEMD	0,0183	0,0090	0,0308	0,0146	0,0135	0,0089	0,0218	0,0652	0,0151	0,0141	0,0084	0,0105	0,0205	0,0126	0,0078	0,0075
CEEMDAN+LMD	0,0208	0,0076	0,0440	0,0201	0,0121	0,0100	0,0250	0,0643	0,0135	0,0171	0,0097	0,0086	0,0226	0,0178	0,0073	0,0074
CEEMDAN+VMD	0,0160	0,0142	0,0203	0,0158	0,0139	0,0092	0,0198	0,0952	0,0173	0,0129	0,0105	0,0079	0,0210	0,0223	0,0084	0,0064
EEMD+CEEMDAN	0,0178	0,0081	0,0818	0,0168	0,0111	0,0108	0,0168	0,0655	0,0123	0,0178	0,0102	0,0091	0,0269	0,0170	0,0113	0,0092
EEMD+EEMD	0,0154	0,0105	0,0314	0,0202	0,0169	0,0095	0,0238	0,0663	0,0187	0,0194	0,0086	0,0110	0,0250	0,0169	0,0089	0,0080
EEMD+LMD	0,0232	0,0082	0,0273	0,0177	0,0111	0,0103	0,0208	0,0521	0,0118	0,0215	0,0096	0,0095	0,0198	0,0163	0,0099	0,0078
EEMD+VMD	0,0161	0,0149	0,0289	0,0147	0,0136	0,0107	0,0298	0,0674	0,0130	0,0200	0,0106	0,0103	0,0282	0,0101	0,0096	0,0071
LMD+CEEMDAN	0,0210	0,0100	0,0215	0,0168	0,0090	0,0084	0,0175	0,0407	0,0094	0,0246	0,0080	0,0106	0,0255	0,0124	0,0081	0,0103
LMD+EEMD	0,0136	0,0109	0,0183	0,0177	0,0116	0,0097	0,0274	0,0564	0,0125	0,0160	0,0079	0,0086	0,0274	0,0171	0,0066	0,0103
LMD+LMD	0,0123	0,0081	0,0199	0,0178	0,0111	0,0108	0,0203	0,0562	0,0127	0,0145	0,0072	0,0076	0,0206	0,0210	0,0081	0,0086
LMD+VMD	0,0267	0,0126	0,0372	0,0137	0,0133	0,0086	0,0292	0,0572	0,0155	0,0192	0,0096	0,0073	0,0235	0,0140	0,0078	0,0118
VMD+CEEMDAN	0,0135	0,0137	0,0242	0,0172	0,0088	0,0081	0,0193	0,0466	0,0095	0,0142	0,0073	0,0092	0,0255	0,0196	0,0086	0,0081
VMD+EEMD	0,0143	0,0122	0,0173	0,0150	0,0104	0,0116	0,0221	0,0611	0,0106	0,0201	0,0064	0,0105	0,0400	0,0132	0,0064	0,0079
VMD+LMD	0,0125	0,0152	0,0218	0,0132	0,0168	0,0108	0,0204	0,0791	0,0176	0,0163	0,0145	0,0085	0,0201	0,0148	0,0119	0,0076
VMD+VMD	0,0168	0,0091	0,0428	0,0194	0,0110	0,0118	0,0187	0,0605	0,0128	0,0180	0,0082	0,0118	0,0266	0,0202	0,0101	0,0087

(Renklendirme; her bir ayrıştırma tekniği için aktivasyon fonksiyonlarının en iyi MSE değeri yeşil, en kötü MSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.4. Nisan ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,1652	0,1071	0,1761	0,1278	0,1275	0,1012	0,1404	0,2602	0,1332	0,1188	0,1137	0,0916	0,1918	0,1369	0,0838	0,0918
CEEMDAN+EEMD	0,1354	0,0948	0,1754	0,1210	0,1164	0,0945	0,1477	0,2554	0,1227	0,1187	0,0919	0,1025	0,1431	0,1124	0,0884	0,0864
CEEMDAN+LMD	0,1443	0,0873	0,2099	0,1419	0,1102	0,1002	0,1582	0,2536	0,1163	0,1309	0,0983	0,0928	0,1502	0,1333	0,0856	0,0860
CEEMDAN+VMD	0,1264	0,1190	0,1424	0,1258	0,1179	0,0960	0,1408	0,3085	0,1316	0,1136	0,1025	0,0889	0,1448	0,1494	0,0914	0,0798
EEMD+CEEMDAN	0,1334	0,0903	0,2860	0,1298	0,1055	0,1040	0,1297	0,2559	0,1107	0,1335	0,1008	0,0952	0,1641	0,1303	0,1062	0,0960
EEMD+EEMD	0,1239	0,1023	0,1771	0,1422	0,1301	0,0975	0,1541	0,2576	0,1368	0,1394	0,0927	0,1048	0,1580	0,1299	0,0941	0,0894
EEMD+LMD	0,1523	0,0903	0,1654	0,1329	0,1054	0,1015	0,1441	0,2283	0,1084	0,1466	0,0979	0,0974	0,1408	0,1276	0,0994	0,0886
EEMD+VMD	0,1267	0,1222	0,1701	0,1213	0,1164	0,1033	0,1726	0,2596	0,1141	0,1415	0,1028	0,1017	0,1680	0,1007	0,0979	0,0844
LMD+CEEMDAN	0,1448	0,0998	0,1465	0,1297	0,0948	0,0914	0,1325	0,2018	0,0972	0,1569	0,0892	0,1030	0,1598	0,1113	0,0902	0,1016
LMD+EEMD	0,1168	0,1043	0,1352	0,1332	0,1078	0,0985	0,1656	0,2375	0,1117	0,1263	0,0888	0,0929	0,1654	0,1308	0,0813	0,1016
LMD+LMD	0,1108	0,0901	0,1410	0,1335	0,1055	0,1038	0,1424	0,2371	0,1128	0,1203	0,0846	0,0870	0,1437	0,1448	0,0902	0,0925
LMD+VMD	0,1634	0,1124	0,1928	0,1169	0,1152	0,0925	0,1710	0,2393	0,1244	0,1384	0,0978	0,0852	0,1534	0,1182	0,0885	0,1088
VMD+CEEMDAN	0,1162	0,1170	0,1556	0,1311	0,0939	0,0902	0,1390	0,2158	0,0977	0,1193	0,0852	0,0962	0,1595	0,1399	0,0926	0,0898
VMD+EEMD	0,1197	0,1103	0,1315	0,1225	0,1020	0,1079	0,1486	0,2472	0,1029	0,1418	0,0803	0,1024	0,2000	0,1151	0,0801	0,0890
VMD+LMD	0,1119	0,1231	0,1477	0,1149	0,1294	0,1039	0,1430	0,2813	0,1325	0,1277	0,1203	0,0921	0,1419	0,1216	0,1092	0,0873
VMD+VMD	0,1297	0,0954	0,2068	0,1395	0,1050	0,1085	0,1366	0,2460	0,1132	0,1341	0,0908	0,1086	0,1632	0,1421	0,1003	0,0934

(Renklendirme; her bir ayrıştırma tekniği için aktivasyon fonksiyonlarının en iyi RMSE değeri yeşil, en kötü RMSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.5. Temmuz ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,0097	0,0074	0,0163	0,0104	0,0064	0,0067	0,0139	0,0370	0,0078	0,0131	0,0047	0,0044	0,0156	0,0087	0,0066	0,0060
CEEMDAN+EEMD	0,0113	0,0078	0,0174	0,0110	0,0066	0,0066	0,0102	0,0382	0,0072	0,0151	0,0046	0,0054	0,0218	0,0081	0,0075	0,0044
CEEMDAN+LMD	0,0131	0,0053	0,0407	0,0083	0,0076	0,0048	0,0180	0,0366	0,0088	0,0104	0,0057	0,0051	0,0100	0,0091	0,0060	0,0041
CEEMDAN+VMD	0,0076	0,0062	0,0228	0,0112	0,0060	0,0074	0,0129	0,0308	0,0064	0,0121	0,0046	0,0053	0,0206	0,0081	0,0057	0,0039
EEMD+CEEMDAN	0,0095	0,0055	0,0260	0,0099	0,0067	0,0059	0,0107	0,0305	0,0074	0,0099	0,0042	0,0049	0,0133	0,0099	0,0052	0,0056
EEMD+EEMD	0,0102	0,0061	0,0254	0,0077	0,0086	0,0056	0,0177	0,0538	0,0094	0,0100	0,0047	0,0053	0,0141	0,0121	0,0066	0,0079
EEMD+LMD	0,0202	0,0064	0,0198	0,0111	0,0062	0,0071	0,0116	0,0373	0,0072	0,0087	0,0042	0,0047	0,0165	0,0081	0,0048	0,0049
EEMD+VMD	0,0110	0,0066	0,0187	0,0078	0,0073	0,0045	0,0110	0,0230	0,0082	0,0104	0,0052	0,0053	0,0181	0,0095	0,0060	0,0044
LMD+CEEMDAN	0,0119	0,0069	0,0135	0,0092	0,0105	0,0046	0,0182	0,0310	0,0098	0,0105	0,0061	0,0060	0,0153	0,0096	0,0048	0,0041
LMD+EEMD	0,0097	0,0052	0,0210	0,0092	0,0079	0,0073	0,0120	0,0252	0,0086	0,0141	0,0043	0,0044	0,0214	0,0117	0,0068	0,0051
LMD+LMD	0,0096	0,0065	0,0200	0,0097	0,0064	0,0052	0,0112	0,0312	0,0069	0,0121	0,0050	0,0057	0,0138	0,0084	0,0050	0,0053
LMD+VMD	0,0123	0,0071	0,0274	0,0089	0,0052	0,0061	0,0116	0,0534	0,0060	0,0109	0,0036	0,0058	0,0125	0,0097	0,0047	0,0052
VMD+CEEMDAN	0,0111	0,0092	0,0178	0,0102	0,0066	0,0065	0,0190	0,0317	0,0075	0,0117	0,0050	0,0050	0,0168	0,0096	0,0054	0,0050
VMD+EEMD	0,0100	0,0091	0,0304	0,0106	0,0065	0,0056	0,0096	0,0495	0,0076	0,0080	0,0054	0,0049	0,0206	0,0095	0,0053	0,0055
VMD+LMD	0,0083	0,0072	0,0253	0,0096	0,0064	0,0055	0,0127	0,0376	0,0068	0,0087	0,0049	0,0049	0,0147	0,0124	0,0070	0,0048
VMD+VMD	0,0123	0,0088	0,0188	0,0102	0,0065	0,0066	0,0201	0,0339	0,0074	0,0095	0,0045	0,0046	0,0167	0,0079	0,0043	0,0055

(Renklendirme; her bir ayırıştırma tekniği için aktivasyon fonksiyonlarının en iyi MSE değeri yeşil, en kötü MSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.6. Temmuz ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,0982	0,0860	0,1276	0,1019	0,0802	0,0818	0,1179	0,1924	0,0885	0,1145	0,0687	0,0660	0,1247	0,0931	0,0810	0,0777
CEEMDAN+EEMD	0,1064	0,0886	0,1320	0,1047	0,0813	0,0812	0,1008	0,1954	0,0850	0,1230	0,0675	0,0733	0,1476	0,0903	0,0864	0,0664
CEEMDAN+LMD	0,1145	0,0731	0,2017	0,0913	0,0873	0,0693	0,1342	0,1912	0,0936	0,1018	0,0753	0,0711	0,0999	0,0956	0,0776	0,0641
CEEMDAN+VMD	0,0872	0,0788	0,1510	0,1058	0,0772	0,0858	0,1136	0,1756	0,0802	0,1102	0,0675	0,0728	0,1436	0,0901	0,0757	0,0622
EEMD+CEEMDAN	0,0977	0,0742	0,1612	0,0996	0,0817	0,0770	0,1035	0,1747	0,0858	0,0997	0,0651	0,0700	0,1155	0,0995	0,0724	0,0748
EEMD+EEMD	0,1011	0,0778	0,1592	0,0877	0,0928	0,0746	0,1329	0,2320	0,0970	0,0999	0,0685	0,0728	0,1185	0,1101	0,0809	0,0888
EEMD+LMD	0,1421	0,0800	0,1409	0,1051	0,0790	0,0845	0,1077	0,1930	0,0847	0,0931	0,0648	0,0686	0,1286	0,0899	0,0695	0,0698
EEMD+VMD	0,1048	0,0815	0,1368	0,0886	0,0857	0,0673	0,1049	0,1517	0,0906	0,1018	0,0721	0,0731	0,1345	0,0973	0,0778	0,0662
LMD+CEEMDAN	0,1092	0,0828	0,1164	0,0957	0,1025	0,0680	0,1348	0,1760	0,0990	0,1027	0,0782	0,0773	0,1236	0,0981	0,0693	0,0642
LMD+EEMD	0,0986	0,0721	0,1448	0,0959	0,0891	0,0853	0,1094	0,1587	0,0930	0,1188	0,0659	0,0661	0,1462	0,1082	0,0693	0,0711
LMD+LMD	0,0981	0,0809	0,1416	0,0987	0,0799	0,0724	0,1059	0,1587	0,0828	0,1100	0,0707	0,0754	0,1174	0,0915	0,0707	0,0727
LMD+VMD	0,1110	0,0845	0,1655	0,0944	0,0719	0,0782	0,1078	0,2311	0,0775	0,1046	0,0596	0,0764	0,1117	0,0986	0,0685	0,0723
VMD+CEEMDAN	0,1052	0,0962	0,1334	0,1012	0,0811	0,0808	0,1378	0,1782	0,0868	0,1082	0,0710	0,0710	0,1297	0,0982	0,0735	0,0706
VMD+EEMD	0,1002	0,0953	0,1743	0,1029	0,0806	0,0751	0,0980	0,2224	0,0870	0,0893	0,0737	0,0697	0,1437	0,0975	0,0730	0,0741
VMD+LMD	0,0909	0,0846	0,1590	0,0978	0,0802	0,0742	0,1126	0,1939	0,0822	0,0933	0,0703	0,0699	0,1213	0,1114	0,0835	0,0692
VMD+VMD	0,1111	0,0937	0,1372	0,1009	0,0805	0,0812	0,1417	0,1842	0,0861	0,0973	0,0674	0,0678	0,1294	0,0887	0,0658	0,0745

(Renklendirme; her bir ayrıştırma tekniği için aktivasyon fonksiyonlarının en iyi RMSE değeri yeşil, en kötü RMSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.7. Ekim ayı için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,0044	0,0038	0,0196	0,0058	0,0023	0,0053	0,0054	0,0201	0,0032	0,0064	0,0029	0,0027	0,0058	0,0054	0,0025	0,0031
CEEMDAN+EEMD	0,0051	0,0023	0,0091	0,0047	0,0039	0,0033	0,0057	0,0409	0,0032	0,0091	0,0041	0,0036	0,0086	0,0045	0,0024	0,0024
CEEMDAN+LMD	0,0046	0,0027	0,0084	0,0061	0,0056	0,0030	0,0067	0,0533	0,0035	0,0041	0,0025	0,0031	0,0129	0,0063	0,0030	0,0029
CEEMDAN+VMD	0,0052	0,0038	0,0075	0,0051	0,0025	0,0033	0,0053	0,0139	0,0042	0,0091	0,0018	0,0035	0,0127	0,0061	0,0033	0,0013
EEMD+CEEMDAN	0,0066	0,0035	0,0105	0,0066	0,0038	0,0027	0,0069	0,0160	0,0045	0,0041	0,0022	0,0032	0,0144	0,0065	0,0023	0,0020
EEMD+EEMD	0,0044	0,0025	0,0083	0,0059	0,0036	0,0027	0,0051	0,0156	0,0045	0,0065	0,0022	0,0039	0,0078	0,0052	0,0036	0,0032
EEMD+LMD	0,0028	0,0029	0,0068	0,0066	0,0043	0,0029	0,0083	0,0258	0,0030	0,0069	0,0038	0,0027	0,0096	0,0043	0,0032	0,0030
EEMD+VMD	0,0073	0,0028	0,0058	0,0076	0,0027	0,0048	0,0079	0,0155	0,0040	0,0071	0,0029	0,0026	0,0050	0,0059	0,0020	0,0020
LMD+CEEMDAN	0,0045	0,0034	0,0049	0,0041	0,0034	0,0045	0,0066	0,0382	0,0032	0,0051	0,0035	0,0021	0,0063	0,0059	0,0019	0,0023
LMD+EEMD	0,0055	0,0034	0,0091	0,0048	0,0024	0,0024	0,0079	0,0307	0,0035	0,0026	0,0023	0,0018	0,0101	0,0051	0,0018	0,0026
LMD+LMD	0,0045	0,0029	0,0043	0,0056	0,0020	0,0034	0,0074	0,0255	0,0036	0,0068	0,0020	0,0027	0,0075	0,0037	0,0033	0,0028
LMD+VMD	0,0049	0,0027	0,0055	0,0043	0,0052	0,0026	0,0098	0,0215	0,0061	0,0077	0,0024	0,0014	0,0081	0,0063	0,0026	0,0029
VMD+CEEMDAN	0,0038	0,0019	0,0092	0,0078	0,0050	0,0020	0,0050	0,0199	0,0033	0,0041	0,0028	0,0028	0,0082	0,0063	0,0032	0,0024
VMD+EEMD	0,0089	0,0066	0,0087	0,0051	0,0060	0,0028	0,0043	0,0148	0,0052	0,0063	0,0033	0,0029	0,0088	0,0064	0,0035	0,0024
VMD+LMD	0,0042	0,0066	0,0081	0,0042	0,0035	0,0029	0,0032	0,0187	0,0039	0,0074	0,0031	0,0030	0,0128	0,0049	0,0020	0,0032
VMD+VMD	0,0063	0,0039	0,0053	0,0042	0,0056	0,0032	0,0073	0,0301	0,0032	0,0100	0,0029	0,0025	0,0072	0,0056	0,0023	0,0019

(Renklendirme; her bir ayırıştırma tekniği için aktivasyon fonksiyonlarının en iyi MSE değeri yeşil, en kötü MSE değeri kırmızı olacak şekilde yapılmıştır.)

Tablo 4.8. Ekim ayı için hibrit modellere ait Kök Ortalama Kare Hatası (RMSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI															
	TANSIG	LOGSIG	PURELIN	MORLET	MEXICAN HAT	POLYWOG1	POLYWOG2	POLYWOG3	POLYWOG4	POLYWOG5	RASP1	RASP2	RASP3	SHANNON	SLOG1	SLOG2
CEEMDAN+CEEMDAN	0,0663	0,0620	0,1399	0,0761	0,0477	0,0725	0,0733	0,1418	0,0568	0,0800	0,0538	0,0518	0,0762	0,0736	0,0499	0,0556
CEEMDAN+EEMD	0,0712	0,0484	0,0954	0,0685	0,0621	0,0576	0,0757	0,2022	0,0563	0,0952	0,0643	0,0604	0,0925	0,0670	0,0491	0,0486
CEEMDAN+LMD	0,0680	0,0519	0,0917	0,0778	0,0745	0,0547	0,0817	0,2308	0,0589	0,0637	0,0504	0,0560	0,1136	0,0791	0,0550	0,0540
CEEMDAN+VMD	0,0719	0,0613	0,0868	0,0716	0,0503	0,0578	0,0730	0,1178	0,0652	0,0956	0,0421	0,0588	0,1125	0,0783	0,0578	0,0358
EEMD+CEEMDAN	0,0812	0,0589	0,1022	0,0810	0,0619	0,0520	0,0828	0,1265	0,0670	0,0640	0,0472	0,0568	0,1202	0,0804	0,0478	0,0448
EEMD+EEMD	0,0660	0,0504	0,0912	0,0768	0,0599	0,0520	0,0717	0,1247	0,0674	0,0805	0,0466	0,0623	0,0881	0,0723	0,0601	0,0568
EEMD+LMD	0,0534	0,0543	0,0822	0,0812	0,0656	0,0539	0,0914	0,1606	0,0549	0,0828	0,0620	0,0516	0,0981	0,0656	0,0569	0,0551
EEMD+VMD	0,0853	0,0528	0,0760	0,0870	0,0518	0,0695	0,0887	0,1245	0,0635	0,0843	0,0541	0,0508	0,0706	0,0766	0,0446	0,0453
LMD+CEEMDAN	0,0672	0,0581	0,0703	0,0642	0,0582	0,0671	0,0813	0,1954	0,0567	0,0711	0,0588	0,0462	0,0796	0,0771	0,0442	0,0482
LMD+EEMD	0,0741	0,0582	0,0956	0,0694	0,0495	0,0485	0,0890	0,1752	0,0596	0,0513	0,0481	0,0428	0,1007	0,0712	0,0424	0,0513
LMD+LMD	0,0674	0,0538	0,0652	0,0752	0,0445	0,0581	0,0862	0,1596	0,0603	0,0825	0,0442	0,0517	0,0867	0,0610	0,0571	0,0532
LMD+VMD	0,0699	0,0519	0,0745	0,0659	0,0719	0,0506	0,0990	0,1466	0,0779	0,0878	0,0486	0,0378	0,0900	0,0793	0,0512	0,0542
VMD+CEEMDAN	0,0620	0,0432	0,0958	0,0883	0,0707	0,0446	0,0708	0,1412	0,0578	0,0638	0,0533	0,0525	0,0906	0,0794	0,0565	0,0491
VMD+EEMD	0,0942	0,0811	0,0932	0,0715	0,0772	0,0530	0,0657	0,1218	0,0724	0,0795	0,0574	0,0540	0,0937	0,0801	0,0593	0,0485
VMD+LMD	0,0650	0,0813	0,0898	0,0652	0,0595	0,0540	0,0563	0,1366	0,0621	0,0859	0,0557	0,0551	0,1129	0,0703	0,0450	0,0565
VMD+VMD	0,0791	0,0623	0,0730	0,0649	0,0746	0,0562	0,0857	0,1736	0,0565	0,1000	0,0536	0,0497	0,0851	0,0748	0,0477	0,0436

(Renklendirme; her bir ayırıştırma tekniği için aktivasyon fonksiyonlarının en iyi RMSE değeri yeşil, en kötü RMSE değeri kırmızı olacak şekilde yapılmıştır.)

Dört mevsim için seçilen 4 farklı aya ait simülasyon sonuçlarına göre, ayrıştırma modellerinde genel olarak, DSA aktivasyon fonksiyonlarından SLOG1, SLOG2, RASP1, RASP2, MEXICAN HAT ve POLYWOG1 aktivasyon fonksiyonlarının, YSA aktivasyon fonksiyonlarından ise TANSIG ve LOGSIG aktivasyon fonksiyonlarının diğerlerine göre daha başarılı olduğu gözlenmektedir. Yılın diğer ayları için yapılacak simülasyonlarda, bu 8 aktivasyon fonksiyonu ile devam edilmesine karar verilmiştir.

Yukarıdaki mevsim bazlı seçilen ayların MSE sonuçlarında her aya ait en iyi 8 ayrıştırma modeli sıralanarak istatistiksel olarak incelendiğinde aşağıdaki tabloda verilen sonuçlara ulaşılmıştır.

Tablo 4.1 - 4.2 - 4.3 - 4.4 - 4.5 - 4.6 - 4.7 - 4.8'deki verilere göre en iyi 8 model arasında bulunma yüzdesi %75 ve üzerinde olan modeller, yılın diğer ayları için yapılacak simülasyonların ayrıştırma modelleri olarak seçilmiştir.

Tablo 4.9. En iyi 8 model sıralamasında bulunma yüzdesi

Ayrıştırma Tekniği	Mevsimler için seçilen 4 aya ait simülasyonlarda, her ayın en iyi 8 modelinde bulunma yüzdesi
CEEMDAN+VMD	%100
EEMD+VMD	%75
LMD+LMD	%75
VMD+CEEMDAN	%75
LMD+EEMD	%75
LMD+VMD	%75
EEMD+LMD	%50
VMD+EEMD	%50
EEMD+CEEMDAN	%50
LMD+CEEMDAN	%50
VMD+VMD	%50
CEEMDAN+EEMD	%25
CEEMDAN+CEEMDAN	%25
CEEMDAN+LMD	%25

6 adet ikili ayrıştırma modeli ve 8 adet aktivasyon fonksiyonu (2 adet klasik YSA+6 adet DSA aktivasyon fonksiyonu) ile oluşturulmuş olan 48 hibrit model için 2020 yılına ait her ayın ilk günü için yapılan 10 dakika çözünürlüklü 24 saatlik rüzgar hızı tahminlerinin sonuçlarının MSE hata oranları cinsinden değerlendirmeleri Tablo 4.10 - 4.11 - 4.12 - 4.13 - 4.14 - 4.15 - 4.16 -

4.17 - 4.18 - 4.19 - 4.20 - 4.21’de verilmiştir. Renklendirme; her bir ayırıştırma tekniği için aktivasyon fonksiyonlarının en iyi MSE değeri yeşil, en kötü MSE değeri kırmızı olacak şekilde yapılmıştır. Ayrıca, her ayın tüm hibrit yapılar içinde en başarılı 3 modeli pembe renk ile renklendirilmiştir.

Tablo 4.10. 1 Ocak 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,01291	0,00627	0,00682	0,00710	0,00702	0,00654	0,00465	0,00372
EEMD+VMD	0,01194	0,00627	0,00796	0,00590	0,00722	0,00799	0,00398	0,00379
LMD+EEMD	0,01268	0,00879	0,00739	0,00723	0,00681	0,00644	0,00470	0,00470
LMD+LMD	0,01214	0,00783	0,00640	0,01006	0,00687	0,00581	0,00452	0,00438
LMD+VMD	0,01152	0,00711	0,00687	0,00752	0,00637	0,00660	0,00494	0,00602
VMD+CEEMDAN	0,01541	0,00703	0,00753	0,00493	0,00567	0,00609	0,00590	0,00449

Tablo 4.11. 1 Şubat 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,01015	0,00798	0,00736	0,01030	0,00617	0,00683	0,00698	0,00367
EEMD+VMD	0,01486	0,00806	0,00809	0,00632	0,00673	0,00791	0,00458	0,00504
LMD+EEMD	0,01189	0,00667	0,00880	0,00743	0,00659	0,00610	0,00529	0,00498
LMD+LMD	0,01364	0,00777	0,01071	0,00684	0,00568	0,00692	0,00447	0,00531
LMD+VMD	0,01008	0,00967	0,00714	0,00535	0,00563	0,00592	0,00441	0,00585
VMD+CEEMDAN	0,01206	0,00979	0,00743	0,00687	0,00673	0,00515	0,00612	0,00645

Tablo 4.12. 1 Mart 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00262	0,00120	0,00157	0,00127	0,00132	0,00110	0,00133	0,00092
EEMD+VMD	0,00227	0,00138	0,00127	0,00136	0,00107	0,00116	0,00100	0,00123
LMD+EEMD	0,00225	0,00181	0,00164	0,00152	0,00121	0,00122	0,00158	0,00109
LMD+LMD	0,00233	0,00159	0,00163	0,00156	0,00113	0,00104	0,00093	0,00135
LMD+VMD	0,00264	0,00171	0,00117	0,00138	0,00106	0,00116	0,00113	0,00111
VMD+CEEMDAN	0,00198	0,00170	0,00156	0,00123	0,00120	0,00135	0,00124	0,00146

Tablo 4.13. 1 Nisan 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,01597	0,01415	0,01389	0,00921	0,01050	0,00790	0,00836	0,00636
EEMD+VMD	0,01605	0,01494	0,01355	0,01067	0,01057	0,01034	0,00958	0,00713
LMD+EEMD	0,01363	0,01088	0,01162	0,00970	0,00789	0,00863	0,00662	0,01033
LMD+LMD	0,01227	0,00812	0,01113	0,01077	0,00716	0,00757	0,00814	0,00856
LMD+VMD	0,02670	0,01263	0,01328	0,00856	0,00957	0,00725	0,00783	0,01184
VMD+CEEMDAN	0,01349	0,01368	0,00882	0,00814	0,00727	0,00925	0,00857	0,00806

Tablo 4.14. 1 Mayıs 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00422	0,00206	0,00203	0,00153	0,00151	0,00207	0,00128	0,00114
EEMD+VMD	0,00203	0,00171	0,00201	0,00190	0,00133	0,00129	0,00152	0,00139
LMD+EEMD	0,00323	0,00200	0,00293	0,00204	0,00157	0,00176	0,00140	0,00147
LMD+LMD	0,00339	0,00176	0,00166	0,00209	0,00199	0,00152	0,00130	0,00151
LMD+VMD	0,00276	0,00189	0,00237	0,00129	0,00169	0,00186	0,00162	0,00122
VMD+CEEMDAN	0,00313	0,00183	0,00173	0,00172	0,00150	0,00150	0,00170	0,00145

Tablo 4.15. 1 Haziran 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,01317	0,00905	0,00990	0,00781	0,00679	0,00565	0,00455	0,00373
EEMD+VMD	0,00525	0,00640	0,01048	0,00529	0,00431	0,00697	0,00578	0,00613
LMD+EEMD	0,00937	0,00586	0,00989	0,00389	0,00513	0,00818	0,00455	0,00582
LMD+LMD	0,00811	0,00628	0,00574	0,00678	0,00800	0,00627	0,00485	0,00403
LMD+VMD	0,01535	0,00844	0,00799	0,00427	0,00590	0,00503	0,00851	0,00453
VMD+CEEMDAN	0,01018	0,00726	0,08740	0,01011	0,00549	0,00667	0,00476	0,00541

Tablo 4.16. 1 Temmuz 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00760	0,00621	0,00596	0,00735	0,00455	0,00530	0,00574	0,00387
EEMD+VMD	0,01099	0,00665	0,00734	0,00452	0,00520	0,00535	0,00605	0,00438
LMD+EEMD	0,00973	0,00521	0,00793	0,00728	0,00434	0,00436	0,00679	0,00505
LMD+LMD	0,00963	0,00655	0,00639	0,00524	0,00500	0,00569	0,00500	0,00528
LMD+VMD	0,01233	0,00715	0,00516	0,00612	0,00356	0,00584	0,00469	0,00523
VMD+CEEMDAN	0,01108	0,00925	0,00657	0,00652	0,00504	0,00504	0,00541	0,00498

Tablo 4.17. 1 Ağustos 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00348	0,00347	0,00315	0,00152	0,00252	0,00203	0,00215	0,00129
EEMD+VMD	0,00443	0,00240	0,00157	0,00293	0,00244	0,00180	0,00218	0,00196
LMD+EEMD	0,00412	0,00272	0,00347	0,00222	0,00169	0,00170	0,00170	0,00203
LMD+LMD	0,00340	0,00338	0,00233	0,00250	0,00161	0,00148	0,00290	0,00195
LMD+VMD	0,00482	0,00208	0,00267	0,00193	0,00137	0,00153	0,00159	0,00225
VMD+CEEMDAN	0,00345	0,00217	0,00223	0,00238	0,00215	0,00221	0,00201	0,00293

Tablo 4.18. 1 Eylül 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00782	0,00436	0,00390	0,00411	0,00440	0,00279	0,00341	0,00236
EEMD+VMD	0,00676	0,00538	0,00513	0,00270	0,00441	0,00333	0,00403	0,00308
LMD+EEMD	0,00592	0,00427	0,00423	0,00346	0,00270	0,00387	0,00328	0,00322
LMD+LMD	0,00682	0,00297	0,00487	0,00426	0,00353	0,00266	0,00263	0,00339
LMD+VMD	0,00653	0,00430	0,00372	0,00344	0,00293	0,00389	0,00574	0,00329
VMD+CEEMDAN	0,00894	0,00360	0,00343	0,00422	0,00346	0,00408	0,00310	0,00359

Tablo 4.19. 1 Ekim 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00517	0,00375	0,00253	0,00335	0,00177	0,00346	0,00334	0,00128
EEMD+VMD	0,00727	0,00279	0,00268	0,00483	0,00293	0,00258	0,00199	0,00205
LMD+EEMD	0,00549	0,00338	0,00245	0,00235	0,00232	0,00183	0,00180	0,00263
LMD+LMD	0,00454	0,00289	0,00198	0,00337	0,00195	0,00267	0,00326	0,00283
LMD+VMD	0,00488	0,00269	0,00518	0,00256	0,00236	0,00143	0,00262	0,00294
VMD+CEEMDAN	0,00384	0,00187	0,00499	0,00199	0,00284	0,00276	0,00320	0,00241

Tablo 4.20. 1 Kasım 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00058	0,00073	0,00058	0,00070	0,00044	0,00049	0,00036	0,00033
EEMD+VMD	0,00073	0,00046	0,00057	0,00038	0,00041	0,00043	0,00049	0,00037
LMD+EEMD	0,00076	0,00056	0,00063	0,00053	0,00046	0,00056	0,00050	0,00061
LMD+LMD	0,00080	0,00055	0,00064	0,00044	0,00035	0,00053	0,00051	0,00045
LMD+VMD	0,00093	0,00047	0,00067	0,00071	0,00056	0,00045	0,00047	0,00040
VMD+CEEMDAN	0,00087	0,00067	0,00056	0,00062	0,00061	0,00043	0,00050	0,00047

Tablo 4.21. 1 Aralık 2020 için hibrit modellere ait Ortalama Karesel Hata (MSE) değerleri

AYRIŞTIRMA TEKNİĞİ	AKTİVASYON FONKSİYONLARI							
	TANSIG	LOGSIG	MEXICAN HAT	POLYWOG1	RASP1	RASP2	SLOG1	SLOG2
CEEMDAN+VMD	0,00217	0,00097	0,00108	0,00082	0,00105	0,00111	0,00092	0,00073
EEMD+VMD	0,00125	0,00105	0,00115	0,00119	0,00075	0,00090	0,00094	0,00082
LMD+EEMD	0,00204	0,00147	0,00106	0,00092	0,00075	0,00082	0,00077	0,00108
LMD+LMD	0,00271	0,00116	0,00079	0,00095	0,00087	0,00120	0,00113	0,00086
LMD+VMD	0,00225	0,00133	0,00132	0,00097	0,00088	0,00110	0,00074	0,00098
VMD+CEEMDAN	0,00193	0,00138	0,00095	0,00090	0,00089	0,00086	0,00091	0,00094

4.2. Tartışma

Tez çalışmasının uygulama safhasında tüm aktivasyon fonksiyonları (3 adet YSA + 13 adet DSA, toplam 16 adet) ve tüm ikili ayrıştırma modellerinin (16 adet) oluşturduğu tüm kombinasyonlar, mevsim normallerinin mevsimin ortasında stabil olacağı yaklaşımından yola çıkarak Ocak, Nisan, Temmuz ve Ekim aylarında, aylık 256 adet olmak üzere toplamda 1024 adet simülasyon yapılmıştır. Bu simülasyonlarda, ikili ayrıştırma tekniklerine yapay sinir ağı aktivasyon fonksiyonları bağlamında bakıldığında, YSA aktivasyon fonksiyonlarının başarımının en iyiden başlamak üzere, Tablo 4.22’de gösterildiği üzere, LOGSIG, TANSIG VE PURELIN olduğu görülmektedir.

Tablo 4.22. Mevsim ortası ayların YSA aktivasyon fonksiyonları + ikili ayrıştırma teknikleri yapılarında Ortalama Karesel Hata (MSE) çizelgesi

AYRIŞTIRMA TEKNİĞİ	MEVSİM ORTASI YSA AKTİVASYON FONKSİYONLARI											
	OCAK			NİSAN			TEMMUZ			EKİM		
	TANSIG	LOGSIG	PURELIN	TANSIG	LOGSIG	PURELIN	TANSIG	LOGSIG	PURELIN	TANSIG	LOGSIG	PURELIN
CEEMDAN+CEEMDAN	0,0131	0,0080	0,0289	0,0273	0,0115	0,0310	0,0097	0,0074	0,0163	0,0044	0,0038	0,0196
CEEMDAN+EEMD	0,0155	0,0052	0,0369	0,0183	0,0090	0,0308	0,0113	0,0078	0,0174	0,0051	0,0023	0,0091
CEEMDAN+LMD	0,0089	0,0112	0,0733	0,0208	0,0076	0,0440	0,0131	0,0053	0,0407	0,0046	0,0027	0,0084
CEEMDAN+VMD	0,0129	0,0063	0,0265	0,0160	0,0142	0,0203	0,0076	0,0062	0,0228	0,0052	0,0038	0,0075
EEMD+CEEMDAN	0,0123	0,0085	0,0242	0,0178	0,0081	0,0818	0,0095	0,0055	0,0260	0,0066	0,0035	0,0105
EEMD+EEMD	0,0121	0,0075	0,1443	0,0154	0,0105	0,0314	0,0102	0,0061	0,0254	0,0044	0,0025	0,0083
EEMD+LMD	0,0142	0,0055	0,0197	0,0232	0,0082	0,0273	0,0202	0,0064	0,0198	0,0028	0,0029	0,0068
EEMD+VMD	0,0119	0,0063	0,0299	0,0161	0,0149	0,0289	0,0110	0,0066	0,0187	0,0073	0,0028	0,0058
LMD+CEEMDAN	0,0091	0,0107	0,0160	0,0210	0,0100	0,0215	0,0119	0,0069	0,0135	0,0045	0,0034	0,0049
LMD+EEMD	0,0127	0,0088	0,0134	0,0136	0,0109	0,0183	0,0097	0,0052	0,0210	0,0055	0,0034	0,0091
LMD+LMD	0,0121	0,0078	0,0282	0,0123	0,0081	0,0199	0,0096	0,0065	0,0200	0,0045	0,0029	0,0043
LMD+VMD	0,0115	0,0071	0,0232	0,0267	0,0126	0,0372	0,0123	0,0071	0,0274	0,0049	0,0027	0,0055
VMD+CEEMDAN	0,0154	0,0070	0,0167	0,0135	0,0137	0,0242	0,0111	0,0092	0,0178	0,0038	0,0019	0,0092
VMD+EEMD	0,0160	0,0052	0,0270	0,0143	0,0122	0,0173	0,0100	0,0091	0,0304	0,0089	0,0066	0,0087
VMD+LMD	0,0178	0,0052	0,0338	0,0125	0,0152	0,0218	0,0083	0,0072	0,0253	0,0042	0,0066	0,0081
VMD+VMD	0,0080	0,0052	0,0214	0,0168	0,0091	0,0428	0,0123	0,0088	0,0188	0,0063	0,0039	0,0053

LOGSIG aktivasyon fonksiyonu YSA aktivasyon fonksiyonları arasında öne çıkıyor olsa da 13 adet DSA fonksiyonunun tamamından daha fazla başarımlı gösterememiştir.

DSA aktivasyon fonksiyonlarına, tüm simülasyonların yapılmış olduğu Ocak, Nisan, Temmuz ve Ekim aylarında ikili ayrıştırma teknikleri bağlamında incelendiğinde SLOG1 ve SLOG2 aktivasyon fonksiyonlarının açık ara en iyi başarımlara sahip oldukları görülmektedir. Bu aktivasyon fonksiyonları sırasıyla RASP2, RASP1, POLYWOG1 ve MEXICAN HAT aktivasyon fonksiyonları takip etmektedir (Tablo 4.1-4.3-4.5-4.7).

Tez çalışmamızın bir önceki döneminde, simülasyon yoğunluğunu azaltmak için mevsim ortası seçilerek tüm aktivasyon fonksiyonları ve tüm ikili ayrıştırma kombinasyonları ile yapılan uygulama aylarında, her ayın en iyi 8 modelinde bulunma yüzdesi %75 ve üzeri olan hibrit yapılara ayrıştırma modeli bağlamında bakıldığında. Uyarlanabilir Gürültüyle Tamamlanan Topluluk Ampirik Mod Ayrıştırma (CEEMDAN) yönteminin, ikili ayrıştırmanın ilk adımında seçilen tüm aktivasyon fonksiyonları için en başarılı ayrıştırma metodu görülmektedir.

İkili ayrıştırmanın, ikinci adımında ise. Varyasyonel Mod Ayrıştırma (VMD) yönteminin tüm simülasyonların yapıldığı Ocak, Nisan, Temmuz ve Ekim aylarındaki en iyi 8 modelinde bulunma yüzdesi %75 ve üzeri olan hibrit yapılara göre seçilen 6 adet ikili ayrıştırma modelinin (Tablo 4.9) 3 tanesinde ikincil ayrıştırma metodu olarak karşımıza çıkmaktadır.

Bu durum, zaten daha önce literatür çalışmamızda da karşımıza çıkan. WMD'nin ikincil ayrıştırma yöntemi olarak benimsendiği yaklaşımı destekler niteliktedir.

Tez çalışmamızda ortaya koymuş olduğumuz ayrıştırma model davranışlarının ve YSA/DSA aktivasyon fonksiyonlarının çıktılarının rüzgar verilerinin lineer olmayan ve kendine has yapısı çerçevesinde şekillendiği unutulmamalıdır. Önermiş olduğumuz hibrit model ve alternatifleri farklı veri yapılarında aynı başarıyı göstermeyebileceği unutulmamalıdır.

5. SONUÇLAR

Tez çalışmamızda oluşturmuş olduğumuz 48 hibrit model ile 2020 yılına ait her ayın ilk günleri için yaptığımız simülasyonlar göstermiştir ki, hibrit modelin sinir ağı safhasında Dalgacık Sinir Ağı aktivasyon fonksiyonları, Yapay Sinir Ağı'nın klasik aktivasyon fonksiyonlarına göre daha başarılı sonuçlara ulaşmıştır.

Tüm hibrit modeller bazında incelendiğinde ise 12 ayın 11'inde CEEMDAN+VMD+SLOG2 yapısına sahip hibrit model en iyi sonuçlara ulaşmıştır. Yalnızca 1 Temmuz 2020 tarihine ait yapılan tahminlemede CEEMDAN+VMD+SLOG2 hibrit modeli 0.00031 MSE değer farkı ile ikinci sırada yer almıştır. Referans olarak seçilen 1 Ocak 2020 tarihine ait 6 adet ayrıştırma modeline ait atmosferik verilerin birincil ve ikincil ayrıştırma sonuçları ile bu ayrıştırma modellerinin SLOG2 aktivasyon fonksiyonu ile 40m yükseklikteki rüzgar hızı için yapılmış tahminlemeler, çalışmamızın "EKLER" kısmında verilmiştir.

Sonuç olarak; rüzgar hızı tahminlemesinde ikincil ayrıştırmalı ve dalgacık sinir ağı temelli yeni bir hibrit yaklaşım önerisi ile yola çıktığımız bu yolda, yapmış olduğumuz çalışmalar göstermiştir ki; iki aşamalı veri ayrıştırması ile elde edilen yüksek anlamlı veriler ile dalgacık sinir ağı aktivasyon fonksiyonları ile oluşturulmuş sinir ağları ile yapılan tahminlemelerin başarımları oldukça yüksektir. Ayrıca, elde edilen sonuçlar ışığında; CEEMDAN+VMD+SLOG2 yapısına sahip hibrit tahmin modeli, oluşturduğumuz 256 modellenli mevsim bazlı (Ocak-Nisan-Temmuz-Ekim) tahminlemede ve 48 modellenli 12 aylık (Her ayın ilk gününe ait 24 saatlik 10 dakika çözünürlüklü) tahminlemede en başarılı model olarak, ikincil ayrıştırmalı ve dalgacık sinir ağı temelli tahminleme yöntemi için önerdiğimiz hibrit model olmuştur.

6. KAYNAKLAR

- Adlong, W. (2012). 100% renewables as a focus for environmental education. *Australian Journal of Environmental Education*, 28(2), 125-155. <https://doi.org/10.1017/aee.2013.5>
- Adnan, R., Liang, Z., Yuan, X., Kisi, O., Akhlaq, M., & Li, B. (2019). Comparison of lssvr, m5rt, nf-gp, and nf-sc models for predictions of hourly wind speed and wind power based on cross-validation. *Energies*, 12(2), 329. <https://doi.org/10.3390/en12020329>
- Ahmed, J. and Sarma, A. (2006). Artificial neural network model for synthetic streamflow generation. *Water Resources Management*, 21(6), 1015-1029. <https://doi.org/10.1007/s11269-006-9070-y>
- Ahmed, M. and Shimada, K. (2019). The effect of renewable energy consumption on sustainable economic development: evidence from emerging and developing economies. *Energies*, 12(15), 2954. <https://doi.org/10.3390/en12152954>
- Ai, X., Li, S., & Xu, H. (2023). Wind speed prediction model using ensemble empirical mode decomposition, least squares support vector machine and long short-term memory. *Frontiers in Energy Research*, 10. <https://doi.org/10.3389/fenrg.2022.1043867>
- Alexandridis, A. and Zaprani, A. (2013). Wavelet neural networks: a practical guide. *Neural Networks*, 42, 1-27. <https://doi.org/10.1016/j.neunet.2013.01.008>
- Ali, M., Khan, A., & Rehman, N. (2017). Hybrid multiscale wind speed forecasting based on variational mode decomposition. *International Transactions on Electrical Energy Systems*, 28(1), e2466. <https://doi.org/10.1002/etep.2466>
- Alsagr, N. and Hemmen, S. (2021). The impact of financial development and geopolitical risk on renewable energy consumption: evidence from emerging markets. *Environmental Science and Pollution Research*, 28(20), 25906-25919. <https://doi.org/10.1007/s11356-021-12447-2>
- Amk, E. and Ms, S. (2021). Environmental impacts of renewable energy in egypt (review article). *Egyptian Journal of Occupational Medicine*, 45(1), 1-16. <https://doi.org/10.21608/ejom.2021.143330>
- An, X. and Tang, Y. (2016). Application of variational mode decomposition energy distribution to bearing fault diagnosis in a wind turbine. *Transactions of the Institute of Measurement and Control*, 39(7), 1000-1006. <https://doi.org/10.1177/0142331215626247>
- Anderson, K., Laws, N., Marr, S., Lisell, L., Jimenez, T., Case, T., ... & Cutler, D. (2018). Quantifying and monetizing renewable energy resiliency. *Sustainability*, 10(4), 933. <https://doi.org/10.3390/su10040933>
- Arango-Argoty, G., Garner, E., Pruden, A., Heath, L., Vikesland, P., & Zhang, L. (2018). Deeparg: a deep learning approach for predicting antibiotic resistance genes from metagenomic data. *Microbiome*, 6(1). <https://doi.org/10.1186/s40168-018-0401-z>
- Aswani, K. and Menaka, D. (2020). A dual autoencoder and singular value decomposition based feature optimization for the detection of brain tumor from mri images. *BMC Medical Imaging*. <https://doi.org/10.21203/rs.3.rs-116329/v1>
- Baluja, S. and Fischer, I. (2018). Learning to attack: adversarial transformation networks. *Proceedings of the Aaai Conference on Artificial Intelligence*, 32(1). <https://doi.org/10.1609/aaai.v32i1.11672>
- Bardwell, L. (2020). Cancer mutations: molecular mekanisms. *Current Biology*, 30(5), R222-R224. <https://doi.org/10.1016/j.cub.2020.01.039>

- Bennouna, K., Chougrad, H., Khamlichi, Y., Boushaki, A., & Ali, S. (2021). Variational autoencoders versus denoising autoencoders for recommendations., 179-188. https://doi.org/10.1007/978-981-33-6893-4_17
- Berrezek, F., Khelil, K., & Bouadjila, T. (2019). Efficient wind speed forecasting using discrete wavelet transform and artificial neural networks. *Revue D Intelligence Artificielle*, 33(6), 447-452. <https://doi.org/10.18280/ria.330607>
- Bian, K., Zhou, M., Hu, F., Lai, W., & Huang, M. (2020). Ceemd: a new method to identify mine water inrush based on the signal processing and laser-induced fluorescence. *Ieee Access*, 8, 107076-107086. <https://doi.org/10.1109/access.2020.3000333>
- Billah, B., King, M., Snyder, R., & Koehler, A. (2006). Exponential smoothing model selection for forecasting. *International Journal of Forecasting*, 22(2), 239-247. <https://doi.org/10.1016/j.ijforecast.2005.08.002>
- Blanchard, T. ve Samanta, B. (2019). Wind speed forecasting using neural networks. *Wind Engineering*, 44(1), 33-48. <https://doi.org/10.1177/0309524x19849846>
- Boubaker, H., Canarella, G., Gupta, R., & Miller, S. (2022). A hybrid arfima wavelet artificial neural network model for djia index forecasting. *Computational Economics*. <https://doi.org/10.1007/s10614-022-10320-z>
- Brahimi, T. (2019). Using artificial intelligence to predict wind speed for energy application in Saudi Arabia. *Energies*, 12(24), 4669. <https://doi.org/10.3390/en12244669>
- Brito, R., Biuk-Aghai, R., & Fong, S. (2021). Gpu-based parallel shadow features generation at neural system for improving gait human activity recognition. *Multimedia Tools and Applications*, 80(8), 12293-12308. <https://doi.org/10.1007/s11042-020-10274-0>
- Cao, Z., Wang, L., & Melo, G. (2017). Multiple-weight recurrent neural networks. *Twenty-Sixth International Joint Conference on Artificial Intelligence*, 1483-1489. <https://doi.org/10.24963/ijcai.2017/205>
- Castellani, F., Astolfi, D., & Natili, F. (2021). Scada data analysis methods for diagnosis of electrical faults to wind turbine generators. *Applied Sciences*, 11(8), 3307. <https://doi.org/10.3390/app11083307>
- Chen, D., Lin, J., & Li, Y. (2018). Modified complementary ensemble empirical mode decomposition and intrinsic mode functions evaluation index for high-speed train gearbox fault diagnosis. *Journal of Sound and Vibration*, 424, 192-207. <https://doi.org/10.1016/j.jsv.2018.03.018>
- Chen, G., Li, L., Zhang, Z., & Li, S. (2020). Short-term wind speed forecasting with principle-subordinate predictor based on conv-lstm and improved bpnn. *Ieee Access*, 8, 67955-67973. <https://doi.org/10.1109/access.2020.2982839>
- Chen, J., Chen, J., Zhu, L., Duan, X., & Liu, Y. (2018). Wind Speed Prediction with Spatio-Temporal Correlation: A Deep Learning Approach. *Energies*, 11(4), 705. <https://doi.org/10.3390/en11040705>
- Chen, J., Mao, Q., & Liu, D. (2020). Dual-path transformer network: direct context-aware modeling for end-to-end monaural speech separation. *Interspeech 2020*, 2642-2646. <https://doi.org/10.21437/interspeech.2020-2205>
- Chen, J., Saunders, K., & Whan, K. (2021). Quality control and bias adjustment of crowdsourced wind speed observations. *Quarterly Journal of the Royal Meteorological Society*, 147(740), 3647-3664. <https://doi.org/10.1002/qj.4146>
- Chen, J., Xue, X., Ha, M., Yu, D., & Ma, L. (2014). Support vector regression method for wind speed prediction incorporating probability prior knowledge. *Mathematical Problems in Engineering*, 2014, 1-10. <https://doi.org/10.1155/2014/410489>

- Chen, N. (2023). Visual recognition and prediction analysis of china's real estate index and stock trend based on cnn-lstm algorithm optimized by neural networks. *Plos One*, 18(2), e0282159. <https://doi.org/10.1371/journal.pone.0282159>
- Chen, N., Zheng, Q., & Meng, X. (2013). Multistep wind speed forecasting based on wavelet and gaussian processes. *Mathematical Problems in Engineering*, 2013, 1-8. <https://doi.org/10.1155/2013/461983>
- Chen, P., Wu, Y., Meng, J., He, P., Li, D., Coffman, D., ... & Guan, D. (2022). The heterogeneous role of energy policies in the energy transition of asia-pacific emerging economies. *Nature Energy*, 7(7), 588-596. <https://doi.org/10.1038/s41560-022-01029-2>
- Chen, X., Xu, C., Yang, X., Song, L., & Tao, D. (2019). Gated-gan: adversarial gated networks for multi-collection style transfer. *Ieee Transactions on Image Processing*, 28(2), 546-560. <https://doi.org/10.1109/tip.2018.2869695>
- Choi, K., Fazekas, G., Sandler, M., & Cho, K. (2017). Convolutional recurrent neural networks for music classification.. <https://doi.org/10.1109/icassp.2017.7952585>
- Choi, S., Shin, J., Liu, P., & Choi, Y. (2022). Argan: adversarially robust generative adversarial networks for deep neural networks against adversarial examples. *Ieee Access*, 10, 33602-33615. <https://doi.org/10.1109/access.2022.3160283>
- Chung, J. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. In *NIPS 2014 Workshop on Deep Learning*. <https://doi.org/10.48550/arxiv.1412.3555>
- Cichocki, A., Mandic, D., Phan, A., Zhou, G., Zhao, Q., Caiafa, C., ... & Lathauwer, L. (2015). Tensor decompositions for signal processing applications: from two-way to multiway component analysis. *Ieee Signal Processing Magazine*, 32(2), 145-163. <https://doi.org/10.1109/msp.2013.2297439>
- Cusack, D., Chou, W., Yang, W., Harmon, M., & Silver, W. (2009). Controls on long-term root and leaf litter decomposition in neotropical forests. *Global Change Biology*, 15(5), 1339-1355. <https://doi.org/10.1111/j.1365-2486.2008.01781.x>
- Deppe, A., Gallus, W., & Takle, E. (2013). A wrf ensemble for improved wind speed forecasts at turbine height. *Weather and Forecasting*, 28(1), 212-228. <https://doi.org/10.1175/waf-d-11-00112.1>
- Doersch, C. (2016). Tutorial on variational autoencoders. *Computer Science, Mathematics*. <https://doi.org/10.48550/arxiv.1606.05908>
- Droste, A., Heusinkveld, B., Fenner, D., & Steeneveld, G. (2020). Assessing the potential and application of crowdsourced urban wind data. *Quarterly Journal of the Royal Meteorological Society*, 146(731), 2671-2688. <https://doi.org/10.1002/qj.3811>
- Eide, S., Bremnes, J., & Steinsland, I. (2017). Bayesian Model Averaging for Wind Speed Ensemble Forecasts Using Wind Speed and Direction. *Weather and Forecasting*, 32(6), 2217-2227. <https://doi.org/10.1175/waf-d-17-0091.1>
- El-Dakkak, O., Feng, S., Wahbah, M., EL-Fouly, T., & Zahawi, B. (2019). Combinatorial method for bandwidth selection in wind speed kernel density estimation. *Iet Renewable Power Generation*, 13(10), 1670-1680. <https://doi.org/10.1049/iet-rpg.2018.5643>
- Elsaraiti, M. ve Merabet, A. (2021) A Comparative Analysis of the ARIMA and LSTM Predictive Models and Their Effectiveness for Predicting Wind Speed. *Energies*, 14(20), 6782. <https://doi.org/10.3390/en14206782>
- Eltouny, K., Gomaa, M., & Liang, X. (2023). Unsupervised learning methods for data-driven vibration-based structural health monitoring: a review. *Sensors*, 23(6), 3290. <https://doi.org/10.3390/s23063290>

- Fang, L. ve Sun, H. (2018). Study on EEMD-Based KICA and Its Application in Fault-Feature Extraction of Rotating Machinery. *Applied Sciences*, 8(9), 1441. <https://doi.org/10.3390/app8091441>
- Fazelpour, F., Tarashkar, N., & Rosen, M. (2016). Short-term wind speed forecasting using artificial neural networks for Tehran, Iran. *International Journal of Energy and Environmental Engineering*, 7(4), 377-390. <https://doi.org/10.1007/s40095-016-0220-6>
- Feng, C., Xu, K., & Ma, H. (2022). Research on impulse power load forecasting based on improved recurrent neural networks. *Computational Intelligence and Neuroscience*, 2022, 1-9. <https://doi.org/10.1155/2022/2784563>
- Ferdinando, H., Seppänen, T., & Alasaarela, E. (2016). Comparing features from ECG pattern and HRV analysis for emotion recognition system. 2016 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), 1-6. <https://doi.org/10.1109/cibcb.2016.7758108>
- Flouros, F., Pistikou, V., & Plakandaras, V. (2022). Geopolitical risk as a determinant of renewable energy investments. *Energies*, 15(4), 1498. <https://doi.org/10.3390/en15041498>
- Fujita, T., Ohashi, T., Yamane, K., Yamamoto, Y., Sone, T., Ohira, Y., ... & Iokawa, K. (2020). Relationship between the number of samples and the accuracy of the prediction model for dressing independence using artificial neural networks in stroke patients. *Japanese Journal of Comprehensive Rehabilitation Science*, 11(0), 28-34. <https://doi.org/10.11336/jjcrs.11.28>
- Fukuoka, R., Suzuki, H., Kitajima, T., Kuwahara, A., & Yasuno, T. (2018). Wind speed prediction model using lstm and 1d-cnn. *Journal of Signal Processing*, 22(4), 207-210. <https://doi.org/10.2299/jsp.22.207>
- G, S., Resmi, R., & Raphael, D. (2020). Artificial intelligence-based wind forecasting using variational mode decomposition. *Computational Intelligence*, 37(3), 1034-1046. <https://doi.org/10.1111/coin.12331>
- Gallagher, C. and Holloway, T. (2020). Integrating air quality and public health benefits in u.s. decarbonization strategies. *Frontiers in Public Health*, 8. <https://doi.org/10.3389/fpubh.2020.563358>
- Gao, Z, g., Wang, X., Bb, G., Bi, J., & Ming, S. (2021). A deep molecular generative model based on multi-resolution graph variational autoencoders. *Theoretical and Computational Chemistry*. <https://doi.org/10.26434/chemrxiv.14692551.v1>
- Gilbert, R. (1988). Statistical Methods for Environmental Pollution Monitoring. *Journal of the American Statistical Association*, 83(404), 1226. <https://doi.org/10.2307/2290180>
- Giorgi, M., Campilongo, S., Ficarella, A., & Congedo, P. (2014). Comparison between wind power prediction models based on wavelet decomposition with least-squares support vector machine (ls-svm) and artificial neural network (ann). *Energies*, 7(8), 5251-5272. <https://doi.org/10.3390/en7085251>
- Guasti, W. and Santos, I. (2021). Solving differential equations using feedforward neural networks., 385-399. https://doi.org/10.1007/978-3-030-86973-1_27
- Guerreiro, A., McMillan, L., & Araujo, C. (2007). Boolean logic with a feneuron. *Integrated Ferroelectrics*, 89(1), 131-140. <https://doi.org/10.1080/10584580601077690>
- Güney, T. (2019). Renewable energy, non-renewable energy and sustainable development. *International Journal of Sustainable Development & World Ecology*, 26(5), 389-397. <https://doi.org/10.1080/13504509.2019.1595214>

- Han, L., Zhang, R., Wang, X., Bao, A., & Jing, H. (2019). Multi-step wind power forecast based on vmd-lstm. *Iet Renewable Power Generation*, 13(10), 1690-1700. <https://doi.org/10.1049/iet-rpg.2018.5781>
- Haque, A., Mandal, P., Meng, J., & Negnevitsky, M. (2013). Wind speed forecast model for wind farm based on a hybrid machine learning algorithm. *International Journal of Sustainable Energy*, 34(1), 38-51. <https://doi.org/10.1080/14786451.2013.826224>
- Hardjita, P. and Hidayat, R. (2022). Sentiment analysis of tweets on prakerja card using convolutional neural network and naive bayes. *Ijid (International Journal on Informatics for Development)*, 10(2), 82-91. <https://doi.org/10.14421/ijid.2021.3007>
- Heydari, A., Nezhad, M., Neshat, M., Garcia, D., Keynia, F., Santoli, L., ... & Tjernberg, L. (2021). A combined fuzzy gmdh neural network and grey wolf optimization application for wind turbine power production forecasting considering scada data. *Energies*, 14(12), 3459. <https://doi.org/10.3390/en14123459>
- Heydari, S., Ayatollahi, S., & Zare, N. (2011). Comparison of artificial neural networks with logistic regression for detection of obesity. *Journal of Medical Systems*, 36(4), 2449-2454. <https://doi.org/10.1007/s10916-011-9711-4>
- Holmatov, B. and Hoekstra, A. (2020). The environmental footprint of transport by car using renewable energy. *Earth S Future*, 8(2). <https://doi.org/10.1029/2019ef001428>
- Howard, T. ve Clark, P. (2007). Correction and downscaling of NWP wind speed forecasts. *Meteorological Applications*, 14(2), 105-116. <https://doi.org/10.1002/met.12>
- Hu, W. and Ying, T. (2017). Generating adversarial malware examples for black-box attacks based on GAN. *International Conference on Data Mining and Big Data*. <https://doi.org/10.48550/arxiv.1702.05983>
- Hu, X., Wang, R., Zhou, D., & Xiong, Y. (2020). Neural topic modeling with cycle-consistent adversarial training. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 9018-9030. <https://doi.org/10.48550/arxiv.2009.13971>
- Huang, A., Liu, X., Rao, C., Zhang, Y., & He, Y. (2022). A new container throughput forecasting paradigm under covid-19. *Sustainability*, 14(5), 2990. <https://doi.org/10.3390/su14052990>
- Huang, D., Liu, J., Deng, L., X, L., & Song, Y. (2019). Application of adaptive kalman filter in online monitoring of mine wind speed.. <https://doi.org/10.20944/preprints201903.0048.v1>
- Huang, N., Wu, Y., Cai, G., Zhu, H., Yu, C., Jiang, L., ... & Xing, E. (2019). Short-term wind speed forecast with low loss of information based on feature generation of osvd. *Ieee Access*, 7, 81027-81046. <https://doi.org/10.1109/access.2019.2922662>
- Huang, N., Xing, E., Cai, G., Yu, Z., Qi, B., & Lin, L. (2018). Short-term wind speed forecasting based on low redundancy feature selection. *Energies*, 11(7), 1638. <https://doi.org/10.3390/en11071638>
- Huang, Y., Di, H., Malekian, R., Qi, X., & Li, Z. (2017). Noncontact measurement and detection of instantaneous seismic attributes based on complementary ensemble empirical mode decomposition. *Energies*, 10(10), 1655. <https://doi.org/10.3390/en10101655>
- Huang, Y., Liu, S., & Yang, L. (2018). Wind speed forecasting method using eemd and the combination forecasting method based on gpr and lstm. *Sustainability*, 10(10), 3693. <https://doi.org/10.3390/su10103693>

- Huang, Y., Yang, L., Liu, S., & Wang, G. (2019). Multi-step wind speed forecasting based on ensemble empirical mode decomposition, long short term memory network and error correction strategy. *Energies*, 12(10), 1822. <https://doi.org/10.3390/en12101822>
- Hur, S. (2019). Estimation of useful variables in wind turbines and farms using neural networks and extended kalman filter. *Ieee Access*, 7, 24017-24028. <https://doi.org/10.1109/access.2019.2900079>
- Hussin, N., Yusof, F., Jamaludin, A., & Norrulashikin, S. (2021). Forecasting Wind Speed in Peninsular Malaysia: An Application of ARIMA and ARIMA-GARCH Models. *Pertanika Bilim ve Teknologi Dergisi*, 29(1). <https://doi.org/10.47836/pjst.29.1.02>
- Iannace, G., Ciaburro, G., & Trematerra, A. (2019). Wind turbine noise prediction using random forest regression. *Machines*, 7(4), 69. <https://doi.org/10.3390/machines7040069>
- Ibrahim, A., Mirjalili, S., El-Said, M., Ghoneim, S., Alharthi, M., Ibrahim, T., ... & El-kenawy, E. (2021). Wind Speed Ensemble Forecasting Based on Deep Learning Using Adaptive Dynamic Optimization Algorithm. *Ieee Access*, 9, 125787-125804. <https://doi.org/10.1109/access.2021.3111408>
- Ingenhorst, C., Jacobs, G., Stöbel, L., Schelenz, R., & Juretzki, B. (2021). Method for airborne measurement of the spatial wind speed distribution above complex terrain. *Wind Energy Science*, 6(2), 427-440. <https://doi.org/10.5194/wes-6-427-2021>
- Jafari, Z., Yousefi, A., & Rajabi, S. (2020). Using different types of neural networks in detection the body's readiness for blood donation and determining the value of each of its parameters using genetic algorithm. *Innovaciencia Facultad De Ciencias Exactas Físicas Y Naturales*, 8(1), 1-10. <https://doi.org/10.15649/2346075x.998>
- Jin, J., Wang, B., Yu, M., & Liu, J. (2020). A novel self-adaptive wind speed prediction model considering atmospheric motion and fractal feature. *Ieee Access*, 8, 215892-215903. <https://doi.org/10.1109/access.2020.3041533>
- Kabakuş, N. and Tortum, A. (2019). Comparative analysis of trip generation models according to household characteristics for developed, developing and non-developed provinces in turkey. *Sadhana*, 44(5). <https://doi.org/10.1007/s12046-019-1104-2>
- Kalair, A., Khan, N., Saleem, M., Kalair, A., & Khan, N. (2020). Role of energy storage systems in energy transition from fossil fuels to renewables. *Energy Storage*, 3(1). <https://doi.org/10.1002/est2.135>
- Kampakis, S. (2014). Are non-standard neural behaviors computationally relevant?. *International Conference on Neural Computation Theory and Applications - Volume 0IJCCI*, 32-37. <https://doi.org/10.5220/0005030400320037>
- Kang, A., Tan, Q., Yuan, X., Lei, X., & Yuan, Y. (2017). Short-term wind speed prediction using eemd-lssvm model. *Advances in Meteorology*, 2017, 1-22. <https://doi.org/10.1155/2017/6856139>
- Kara, A., Wallcraft, A., Barron, C., Hurlburt, H., & Bourassa, M. (2008). Accuracy of 10 m winds from satellites and NWP products near land-sea boundaries. *Journal of Geophysical Research Atmospheres*, 113(C10). <https://doi.org/10.1029/2007jc004516>
- Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). Progressive growing of gans for improved quality, stability, and variation. *6th International Conference on Learning Representations*. <https://doi.org/10.48550/arxiv.1710.10196>
- Kechagias-Stamatis, O., Aouf, N., Dubanchet, V., & Richardson, M. (2020). Deeplo: multi-projection deep lidar odometry for space orbital robotics rendezvous relative navigation. *Acta Astronautica*, 177, 270-285. <https://doi.org/10.1016/j.actaastro.2020.07.034>

- Kendall, M. (1971). Time Series Analysis, Forecasting and Control. *Journal of the Royal Statistical Society Series a (General)*, 134(3), 450. <https://doi.org/10.2307/2344246>
- Khan, K. and Su, C. (2022). Does technology innovation complement the renewable energy transition?. *Environmental Science and Pollution Research*, 30(11), 30144-30154. <https://doi.org/10.1007/s11356-022-24336-3>
- Khaw, K. and Ni, T. (2021). Fossil fuel price, carbon dioxide emission, and renewable energy capacity: evidence from asian developing countries. *International Journal of Banking and Finance*, 16. <https://doi.org/10.32890/ijbf2021.16.1.5>
- Kim, B., Azevedo, V., Thuerey, N., Kim, T., Groß, M., & Solenthaler, B. (2019). Deep fluids: a generative network for parameterized fluid simulations. *Computer Graphics Forum*, 38(2), 59-70. <https://doi.org/10.1111/cgf.13619>
- Kingma, D. and Welling, M. (2013). Auto-encoding variational bayes. *International Conference on Learning Representations*. <https://doi.org/10.48550/arxiv.1312.6114>
- Kingma, D. and Welling, M. (2019). An introduction to variational autoencoders. *Now Foundations and Trends*. <https://doi.org/10.1561/9781680836233>
- Knudsen, T., Bak, T., & Soltani, M. (2011). Prediction models for wind speed at turbine locations in a wind farm. *Wind Energy*, 14(7), 877-894. <https://doi.org/10.1002/we.491>
- Koengkan, M. (2017). Is the globalization influencing the primary energy consumption? the case of latin america and caribbean countries. *Cadernos Unifoa*, 12(33), 57-67. <https://doi.org/10.47385/cadunifoa.v12.n33.460>
- Kon, J., Bruijnen, D., Wijdeven, J., Heertjes, M., & Oomen, T. (2022). Physics-guided neural networks for feedforward control: an orthogonal projection-based approach.. <https://doi.org/10.23919/acc53348.2022.9867653>
- Kondo, T., Ueno, J., & Sugiyama, T. (2015). Medical image diagnosis of liver cancer by hybrid feedback gmdh-type neural network using principal component-regression analysis. *Artificial Life and Robotics*, 20(2), 145-151. <https://doi.org/10.1007/s10015-015-0213-1>
- Kristensen, L., Degroote, M., Wittek, P., Aspuru-Guzik, A., & Zinner, N. (2019). An artificial spiking quantum neuron.. <https://doi.org/10.48550/arxiv.1907.06269>
- Krizhevsky, A., Sutskever, I., & Hinton, G. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the Acm*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- Krizhevsky, A., Sutskever, I., & Hinton, G. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the Acm*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- Kumar, J. and Majid, M. (2020). Renewable energy for sustainable development in india: current status, future prospects, challenges, employment, and investment opportunities. *Energy Sustainability and Society*, 10(1). <https://doi.org/10.1186/s13705-019-0232-1>
- Kwietniak, A., Cichostępski, K., & Kasperska, M. (2016). Spectral decomposition using the ceemd method: a case study from the carpathian foredeep. *Acta Geophysica*, 64(5), 1525-1541. <https://doi.org/10.1515/acgeo-2016-0065>
- Lai, S., Xu, L., Liu, K., & Zhao, J. (2015). Recurrent convolutional neural networks for text classification. *Proceedings of the Aaai Conference on Artificial Intelligence*, 29(1). <https://doi.org/10.1609/aaai.v29i1.9513>
- Lang, J. (2021). A novel multi-step cross-decomposition method based on wavelet transform for wind power prediction. *E3s Web of Conferences*, 252, 01015. <https://doi.org/10.1051/e3sconf/202125201015>

- Lang, P. and Gregory, K. (2019). Economic impact of energy consumption change caused by global warming. *Energies*, 12(18), 3575. <https://doi.org/10.3390/en12183575>
- Lawrence, S., Liu, Q., & Yakovenko, V. (2013). Global inequality in energy consumption from 1980 to 2010. *Entropy*, 15(12), 5565-5579. <https://doi.org/10.3390/e15125565>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the Ieee*, 86(11), 2278-2324. <https://doi.org/10.1109/5.726791>
- Lee, J., Cheon, S., Choi, B., Kim, N., & Song, E. (2018). Acoustic modeling using adversarially trained variational recurrent neural network for speech synthesis. *Interspeech 2018*, 917-921. <https://doi.org/10.21437/interspeech.2018-1598>
- Lei, Y., Li, N., Lin, J., & Wang, S. (2013). Fault Diagnosis of Rotating Machinery Based on an Adaptive Ensemble Empirical Mode Decomposition. *Sensors*, 13(12), 16950-16964. <https://doi.org/10.3390/s131216950>
- Lerch, S. ve Thorarinsdottir, T. (2013). Comparison of non-homogeneous regression models for probabilistic wind speed forecasting. *Tellus a Dynamic Meteorology and Oceanography*, 65(1), 21206. <https://doi.org/10.3402/tellusa.v65i0.21206>
- Li, C., Zhan, L., & Shen, L. (2015). Friction signal denoising using complete ensemble emd with adaptive noise and mutual information. *Entropy*, 17(12), 5965-5979. <https://doi.org/10.3390/e17095965>
- Li, D., Heimeriks, G., & Alkemade, F. (2021). Knowledge flows in global renewable energy innovation systems: the role of technological and geographical distance. *Technology Analysis and Strategic Management*, 34(4), 418-432. <https://doi.org/10.1080/09537325.2021.1903416>
- Li, J., Jiang, L., Chen, H., Zhang, Y., & Xie, Y. (2021). Propeller feature extraction of uuv's study based on ceemd combined with symmetric correlation. *Matec Web of Conferences*, 336, 02006. <https://doi.org/10.1051/mateconf/202133602006>
- Li, K., Daniels, J., Liu, C., Herrero, P., & Georgiou, P. (2018). Convolutional recurrent neural networks for glucose prediction.. <https://doi.org/10.48550/arxiv.1807.03043>
- Li, W. and Hou, N. (2022). Aircraft failure rate prediction method based on ceemd and combined model. *Scientific Programming*, 2022, 1-19. <https://doi.org/10.1155/2022/8455629>
- Li, X. and Ding, F. (2016). Application of ceemd-svm in rolling bearing fault recognition.. <https://doi.org/10.2991/mcei-16.2016.304>
- Li, Y., Yang, Z., Wang, Y., & Xu, C. (2021). Neural architecture dilation for adversarial robustness.. <https://doi.org/10.48550/arxiv.2108.06885>
- Liang, M. and Hu, X. (2015). Recurrent convolutional neural network for object recognition. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3367-3375. <https://doi.org/10.1109/cvpr.2015.7298958>
- Liao, K., Zhao, Y., Gu, J., Zhang, Y., & Zhong, Y. (2021). Sequential convolutional recurrent neural networks for fast automatic modulation classification. *Ieee Access*, 9, 27182-27188. <https://doi.org/10.1109/access.2021.3053427>
- Liu, A., Zhang, L., Mei, Y., Han, B., Cai, Z., Zhu, Z., ... & Xiao, J. (2021). Residual recurrent crnn for end-to-end optical music recognition on monophonic scores. *ICMR '21: International Conference on Multimedia Retrieval*, 23-27. <https://doi.org/10.1145/3463945.3469056>
- Liu, F., Gao, J., & Liu, H. (2020). The feature extraction and diagnosis of rolling bearing based on ceemd and ldwpsso-pnn. *Ieee Access*, 8, 19810-19819. <https://doi.org/10.1109/access.2020.2968843>

- Liu, H. and Zhong, K. (2022). Relationship between health spending, life expectancy and renewable energy in china: a new evidence from the vecm approach. *Frontiers in Public Health*, 10. <https://doi.org/10.3389/fpubh.2022.993546>
- Liu, S., Tang, B., Chen, Q., & Wang, X. (2016). Drug-drug interaction extraction via convolutional neural networks. *Computational and Mathematical Methods in Medicine*, 2016, 1-8. <https://doi.org/10.1155/2016/6918381>
- Liu, W., Xu, X., Yang, Z., Zhao, J., & Xing, J. (2016). Impacts of fdi renewable energy technology spillover on china's energy industry performance. *Sustainability*, 8(9), 846. <https://doi.org/10.3390/su8090846>
- Liu, W., Zhang, W., Han, J., & Wang, G. (2012). A new wind turbine fault diagnosis method based on the local mean decomposition. *Renewable Energy*, 48, 411-415. <https://doi.org/10.1016/j.renene.2012.05.018>
- Lu, P., Lin, Y., Sun, B., Zhang, C., Zhao, Y., & Teng, J. (2018). A new hybrid prediction method of ultra-short-term wind power forecasting based on eemd-pe and lssvm optimized by the gsa. *Energies*, 11(4), 697. <https://doi.org/10.3390/en11040697>
- Lundin, M., Lundin, J., Burke, H., Toikkanen, S., Pylkkänen, L., & Joensuu, H. (1999). Artificial neural networks applied to survival prediction in breast cancer. *Oncology*, 57(4), 281-286. <https://doi.org/10.1159/000012061>
- Luo, X., Sun, J., Wang, L., Zhao, W., Wu, J., Wang, J., ... & Zhang, Z. (2018). Short-Term Wind Speed Forecasting via Stacked Extreme Learning Machine With Generalized Correntropy. *Ieee Transactions on Industrial Informatics*, 14(11), 4963-4971. <https://doi.org/10.1109/tii.2018.2854549>
- Ma, Z., Guo, S., Xu, G., & Aziz, S. (2020). Meta learning-based hybrid ensemble approach for short-term wind speed forecasting. *Ieee Access*, 8, 172859-172868. <https://doi.org/10.1109/access.2020.3025811>
- Maheswari, R. and Umamaheswari, R. (2019). Fault diagnostics of wind turbine drive-train using multivariate signal processing., 24(2), 334-342. <https://doi.org/10.20855/ijav.2019.24.21527>
- Mahmud, M., Huang, J., Fu, X., Ruby, R., & Wu, K. (2021). Unsupervised adaptation for high-dimensional with limited-sample data classification using variational autoencoder. *Computing and Informatics*, 40(1), 1-28. https://doi.org/10.31577/cai_2021_1_1
- Mangini, S. (2020). Quantum computing model of an artificial neuron with continuously valued input data. *Machine Learning: Science and Technology*, Volume 1, Number 4. <https://doi.org/10.48550/arxiv.2007.14288>
- Martinho, V. (2018). A transversal perspective on global energy production and consumption: an approach based on convergence theory. *Energy & Environment*, 29(4), 556-575. <https://doi.org/10.1177/0958305x18754379>
- Mauro, G., Luca, M., Longa, A., Lepri, B., & Pappalardo, L. (2022). Generating mobility networks with generative adversarial networks. *Epj Data Science*, 11(1). <https://doi.org/10.1140/epjds/s13688-022-00372-4>
- Mauro, G., Luca, M., Longa, A., Lepri, B., & Pappalardo, L. (2022). Generating mobility networks with generative adversarial networks. *Epj Data Science*, 11(1). <https://doi.org/10.1140/epjds/s13688-022-00372-4>
- Meng, J., Hu, X., Chen, P., Coffman, D., & Han, M. (2020). The unequal contribution to global energy consumption along the supply chain. *Journal of Environmental Management*, 268, 110701. <https://doi.org/10.1016/j.jenvman.2020.110701>

- Mikolov, T. and Zweig, G. (2012). Context dependent recurrent neural network language model. 2012 IEEE Spoken Language Technology Workshop (SLT), 234-239 . <https://doi.org/10.1109/slt.2012.6424228>
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A., Veness, J., Bellemare, M., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533. <https://doi.org/10.1038/nature14236>
- Mohammed, Y., Mostovenko, E., Henneman, A., Marissen, R., Deelder, A., & Palmblad, M. (2012). Cloud parallel processing of tandem mass spectrometry based proteomics data. *Journal of Proteome Research*, 11(10), 5101-5108. <https://doi.org/10.1021/pr300561q>
- Molyneaux, L., Brown, C., Wagner, L., & Foster, J. (2016). Measuring resilience in energy systems: insights from a range of disciplines. *Renewable and Sustainable Energy Reviews*, 59, 1068-1079. <https://doi.org/10.1016/j.rser.2016.01.063>
- Nasr, M. and Chtourou, M. (2006). A hybrid training algorithm for feedforward neural networks. *Neural Processing Letters*, 24(2), 107-117. <https://doi.org/10.1007/s11063-006-9013-x>
- Natekin, A. and Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7. <https://doi.org/10.3389/fnbot.2013.00021>
- Neumeier, M., Tollkuhn, A., Berberich, T., & Botsch, M. (2021). Variational autoencoder-based vehicle trajectory prediction with an interpretable latent space. *IEEE International Conference on Intelligent Transportation Systems (ITSC 2021)*, 820-827. <https://doi.org/10.48550/arxiv.2103.13726>
- Nguyen, H., Li, S., & Cheah, C. (2022). A layer-wise theoretical framework for deep learning of convolutional neural networks. *Ieee Access*, 10, 14270-14287. <https://doi.org/10.1109/access.2022.3147869>
- Nguyen, T. and Phan, Q. (2022). Hourly day ahead wind speed forecasting based on a hybrid model of eemd, cnn-bi-lstm embedded with ga optimization. *Energy Reports*, 8, 53-60. <https://doi.org/10.1016/j.egyr.2022.05.110>
- Ntanos, S., Skordoulis, M., Kyriakopoulos, G., Arabatzis, G., Chalikias, M., Galatsidas, S., ... & Katsarou, A. (2018). Renewable energy and economic growth: evidence from european countries. *Sustainability*, 10(8), 2626. <https://doi.org/10.3390/su10082626>
- Oh, S., Choi, J., & Kim, J. (2020). A tutorial on quantum convolutional neural networks (qcn). <https://doi.org/10.1109/ictc49870.2020.9289439>
- Oh, S., Jung, Y., Kim, S., Lee, I., & Kang, N. (2019). Deep generative design: integration of topology optimization and generative models. *Journal of Mechanical Design*, 141(11). <https://doi.org/10.1115/1.4044229>
- Öztemel, E. (2003). Yapay sinir ağlarına giriş, Yapay sinir ağlarının yapısı ve temel elemanları. *Yapay sinir Ağları*. Papatya Yayıncılık, s.29-58.
- Østergaard, K., Brath, P., & Stoustrup, J. (2007). Estimation of effective wind speed. *Journal of Physics Conference Series*, 75, 012082. <https://doi.org/10.1088/1742-6596/75/1/012082>
- Pagliaro, M. (2019). Renewable energy systems: enhanced resilience, lower costs. *Energy Technology*, 7(11), 1900791. <https://doi.org/10.1002/ente.201900791>
- Panahian, S. and Zainuddin, Z. (2015). Universal approximation property of weighted approximate identity neural networks.. <https://doi.org/10.22323/1.259.0007>
- Park, S. and Kim, H. (2021). Facevae: generation of a 3d geometric object using variational autoencoders. *Electronics*, 10(22), 2792. <https://doi.org/10.3390/electronics10222792>

- Pascanu, R. (2012). On the difficulty of training recurrent neural networks. ICML'13: Proceedings of the 30th International Conference on International Conference on Machine Learning, 1310-1318. <https://doi.org/10.48550/arxiv.1211.5063>
- Phan, Q. and Tan, T. (2023). Quantum-resistant highly accurate wind speed prediction model.. <https://doi.org/10.36227/techrxiv.22180429>
- Poudel, S. and Ray, A. (2020). Speech command recognition using artificial neural networks. Joiv International Journal on Informatics Visualization, 4(2), 73. <https://doi.org/10.30630/joiv.4.2.358>
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A., & Gulin, A. (2017). Catboost: unbiased boosting with categorical features.. <https://doi.org/10.48550/arxiv.1706.09516>
- Qian, L., Zhang, Y., Zheng, L., Shang, Y., Gao, J., & Liu, Y. (2015). Frequency dependent topological patterns of resting-state brain networks. Plos One, 10(4), e0124681. <https://doi.org/10.1371/journal.pone.0124681>
- Qiao, Q., Wang, Q., Ye, M., Wang, M., Lian, G., & Wu, C. (2022). Optimized deep convolutional neural networks based state of charge estimation for lithium-ion battery.. <https://doi.org/10.46855/energy-proceedings-9198>
- Qu, Z., Zhang, K., Wang, J., Zhang, W., & Leng, W. (2016). A hybrid model based on ensemble empirical mode decomposition and fruit fly optimization algorithm for wind speed forecasting. Advances in Meteorology, 2016, 1-14. <https://doi.org/10.1155/2016/3768242>
- Rachmatullah, M., Santoso, J., & Surendro, K. (2021). Determining the number of hidden layer and hidden neuron of neural network for wind speed prediction. Peerj Computer Science, 7, e724. <https://doi.org/10.7717/peerj-cs.724>
- Radford, A. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. Proc. Int. Conf. Learn. Representations. <https://doi.org/10.48550/arxiv.1511.06434>
- Ranard, B., Ha, Y., Meisel, Z., Asch, D., Hill, S., Becker, L., ... & Merchant, R. (2013). Crowdsourcing—harnessing the masses to advance health and medicine, a systematic review. Journal of General Internal Medicine, 29(1), 187-203. <https://doi.org/10.1007/s11606-013-2536-8>
- Ranganayaki, V. and Deepa, S. (2016). An intelligent ensemble neural network model for wind speed prediction in renewable energy systems. The Scientific World Journal, 2016, 1-14. <https://doi.org/10.1155/2016/9293529>
- Ren, Y., Suganthan, P., & Srikanth, N. (2015). A comparative study of empirical mode decomposition-based short-term wind speed forecasting methods. Ieee Transactions on Sustainable Energy, 6(1), 236-244. <https://doi.org/10.1109/tste.2014.2365580>
- Ren, Y., Suganthan, P., & Srikanth, N. (2016). A novel empirical mode decomposition with support vector regression for wind speed forecasting. Ieee Transactions on Neural Networks and Learning Systems, 27(8), 1793-1798. <https://doi.org/10.1109/tnnls.2014.2351391>
- Robert-George, C., Várady, C., Volpi, R., & Malagò, L. (2021). Automatic feature extraction for heartbeat anomaly detection. PharML 2020 Workshop - European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML-PKDD). <https://doi.org/10.48550/arxiv.2102.12289>
- Rozsa, A., Günther, M., & Boulton, T. (2016). Are accuracy and robustness correlated. 15th IEEE International Conference on Machine Learning and Applications (ICMLA), 227-232. <https://doi.org/10.1109/icmla.2016.0045>

- Rueckauer, B., Lungu, I., Hu, Y., Pfeiffer, M., & Liu, S. (2017). Conversion of continuous-valued deep networks to efficient event-driven networks for image classification. *Frontiers in Neuroscience*, 11. <https://doi.org/10.3389/fnins.2017.00682>
- Rumelhart, D., Hinton, G., & Williams, R. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Rymarczyk, T., Wójcik, D., Maciura, Ł., Rosa, W., & Bartosik, M. (2022). Body surface potential mapping time series recognition using convolutional and recurrent neural networks. *Journal of Physics Conference Series*, 2408(1), 012001. <https://doi.org/10.1088/1742-6596/2408/1/012001>
- Saarinen, S., Bramley, R., & Cybenko, G. (1993). Ill-conditioning in neural network training problems. *Siam Journal on Scientific Computing*, 14(3), 693-714. <https://doi.org/10.1137/0914044>
- Saha, S., Rios, T., Minku, L., Stein, B., Yao, X., Bäck, T., ... & Menzel, S. (2021). Exploiting generative models for performance predictions of 3d car designs. *IEEE Symposium Series on Computational Intelligence (SSCI)*, 1-9. <https://doi.org/10.1109/ssci50451.2021.9660034>
- Salimans, T. (2016). Improved techniques for training gans. *Advances in neural information processing systems*, 2016, 2234-2242. <https://doi.org/10.48550/arxiv.1606.03498>
- Saxena, B., Mishra, S., & Rao, K. (2021). Offshore wind speed forecasting at different heights by using ensemble empirical mode decomposition and deep learning models. *Applied Ocean Research*, 117, 102937. <https://doi.org/10.1016/j.apor.2021.102937>
- Scherer, L. and Pfister, S. (2016). Hydropower's biogenic carbon footprint. *Plos One*, 11(9), e0161947. <https://doi.org/10.1371/journal.pone.0161947>
- Scheuerer, M. and Möller, D. (2015). Probabilistic wind speed forecasting on a grid based on ensemble model output statistics. *The Annals of Applied Statistics*, 9(3). <https://doi.org/10.1214/15-aos843>
- Schuster, M. and Paliwal, K. (1997). Bidirectional recurrent neural networks. *Ieee Transactions on Signal Processing*, 45(11), 2673-2681. <https://doi.org/10.1109/78.650093>
- Serwa, A. (2022). Development of soft computational simulator for optimized deep artificial neural networks for geomatics applications: remote sensing classification as an application. *Geodesy and Cartography*, 48(4), 224-232. <https://doi.org/10.3846/gac.2022.15642>
- Seifollahi, M., Lotfollahi-Yaghin, M.A., Kalateh, F., Daneshfaraz, R., Abbasi, S. Abraham, J.(2021). Estimation of the Local Scour from a Cylindrical Bridge Pier Using a CompilationWavelet Model and Artificial Neural Network. *Journal of Hydraulic Structures*, 7(3), 1-22. doi:10.22055/jhs.2021.38300.1187.
- Seifollahi, M., Abbasi, S., Mohammadi, F., Daneshfaraz, R., Babak, A. (2022). Prediction of Crest Settlement in Rock-fill Dams Using ANN and ANFIS. *Conference: 12th International River Engineering Conference*, Shahid Chamran University of Ahvaz.
- Shahbaz, M., Balcilar, M., & Mahalik, M. (2021). Is causality between globalization and energy consumption bidirectional or unidirectional in top and bottom globalized economies?. *International Journal of Finance & Economics*, 28(2), 1939-1964. <https://doi.org/10.1002/ijfe.2519>
- Shahbaz, M., Shahzad, S., Mahalik, M., & Sadorsky, P. (2017). How strong is the causal relationship between globalization and energy consumption in developed economies? a country-specific time-series and panel analysis. *Applied Economics*, 50(13), 1479-1494. <https://doi.org/10.1080/00036846.2017.1366640>

- Shao, T., Guo, Y., Chen, H., & Hao, Z. (2019). Transformer-based neural network for answer selection in question answering. *Ieee Access*, 7, 26146-26156. <https://doi.org/10.1109/access.2019.2900753>
- Shen, D., Wu, G., & Suk, H. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19(1), 221-248. <https://doi.org/10.1146/annurev-bioeng-071516-044442>
- Shimada, S. ve Ohsawa, T. (2011). Wrf ile simüle edilen açık deniz rüzgar hızlarının doğruluğu ve özellikleri. *Sola*, 7, 21-24. <https://doi.org/10.2151/sola.2011-006>
- Shu, X., Bao, T., Zhou, Y., Xu, R., & Zhang, K. (2022). Unsupervised dam anomaly detection with spatial-temporal variational autoencoder. *Structural Health Monitoring*, 22(1), 39-55. <https://doi.org/10.1177/14759217211073301>
- Sonter, L., Dade, M., Watson, J., & Valenta, R. (2020). Renewable energy production will exacerbate mining threats to biodiversity. *Nature Communications*, 11(1). <https://doi.org/10.1038/s41467-020-17928-5>
- YAVUZ, V., Altiner, A., & Bozkurt, E. (2022). The effects of globalization on energy consumption: evidence from eagles. *Business and Management Studies an International Journal*, 10(3), 885-894. <https://doi.org/10.15295/bmij.v10i3.2081>
- Su, Z., Zheng, B., & Lu, H. (2023). A combined model based on secondary decomposition technique and grey wolf optimizer for short-term wind power forecasting. *Frontiers in Energy Research*, 11. <https://doi.org/10.3389/fenrg.2023.1078751>
- Sun, C. and Yang, Y. (2013). Wind speed prediction based on empirical mode decomposition and improved ls-svm.. <https://doi.org/10.1049/cp.2013.1853>
- Sun, G., Su, Y., Qin, C., Wen-bo, X., Lu, X., & Ceglowski, A. (2020). Complete defense framework to protect deep neural networks against adversarial examples. *Mathematical Problems in Engineering*, 2020, 1-17. <https://doi.org/10.1155/2020/8319249>
- Sun, S., Fu, J., & Li, A. (2019). A compound wind power forecasting strategy based on clustering, two-stage decomposition, parameter optimization, and optimal combination of multiple machine learning approaches. *Energies*, 12(18), 3586. <https://doi.org/10.3390/en12183586>
- Sun, W. and 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*, 157, 1-12. <https://doi.org/10.1016/j.enconman.2017.11.067>
- Sundermeyer, M., Oparin, I., Gauvain, J., Freiberg, B., Schlüter, R., & Ney, H. (2013). Comparison of feedforward and recurrent neural network language models.. <https://doi.org/10.1109/icassp.2013.6639310>
- Şenyapar, H. (2023). A bibliometric analysis on renewable energy's public health benefits. *Journal of Energy Systems*, 7(1), 132-157. <https://doi.org/10.30521/jes.1252122>
- Tan, L., Han, J., & Zhang, H. (2020). Ultra-short-term wind power prediction by salp swarm algorithm-based optimizing extreme learning machine. *Ieee Access*, 8, 44470-44484. <https://doi.org/10.1109/access.2020.2978098>
- Tang, L., Dai, W., Yu, L., & Wang, S. (2015). A novel ceemd-based eelm ensemble learning paradigm for crude oil price forecasting. *International Journal of Information Technology & Decision Making*, 14(01), 141-169. <https://doi.org/10.1142/s0219622015400015>
- Taşçıkaraoğlu, A., Sanandaji, B., Poolla, K., & Varaiya, P. (2016). Exploiting sparsity of interconnections in spatio-temporal wind speed forecasting using wavelet transform. *Applied Energy*, 165, 735-747. <https://doi.org/10.1016/j.apenergy.2015.12.082>

- Tatinati, S. and Veluvolu, K. (2013). A hybrid approach for short-term forecasting of wind speed. *The Scientific World Journal*, 2013, 1-8. <https://doi.org/10.1155/2013/548370>
- Thorarinsdottir, T. ve Gneiting, T. (2009). Probabilistic Forecasts of Wind Speed: Ensemble Model Output Statistics by using Heteroscedastic Censored Regression. *Journal of the Royal Statistical Society Series a (Statistics in Society)*, 173(2), 371-388. <https://doi.org/10.1111/j.1467-985x.2009.00616.x>
- Tian, Z., Li, S., & Wang, Y. (2019). A prediction approach using ensemble empirical mode decomposition-permutation entropy and regularized extreme learning machine for short-term wind speed. *Wind Energy*, 23(2), 177-206. <https://doi.org/10.1002/we.2422>
- Ting, D., Carin, L., & Abramoff, M. (2019). Observations and lessons learned from the artificial intelligence studies for diabetic retinopathy screening. *Jama Ophthalmology*, 137(9), 994. <https://doi.org/10.1001/jamaophthalmol.2019.1997>
- Tonami, N., Imoto, K., Yamanishi, R., & Yamashita, Y. (2021). Joint analysis of sound events and acoustic scenes using multitask learning. *Ieice Transactions on Information and Systems*, E104.D(2), 294-301. <https://doi.org/10.1587/transinf.2020edp7036>
- Tucci, M., Barmada, S., Formisano, A., & Thomopoulos, D. (2021). A regularized procedure to generate a deep learning model for topology optimization of electromagnetic devices. *Electronics*, 10(18), 2185. <https://doi.org/10.3390/electronics10182185>
- Tuerxun, W., Xu, C., Guo, H., Guo, L., Zeng, N., & Cheng, Z. (2022). An ultra-short-term wind speed prediction model using lstm based on modified tuna swarm optimization and successive variational mode decomposition. *Energy Science & Engineering*, 10(8), 3001-3022. <https://doi.org/10.1002/ese3.1183>
- Valtierra-Rodriguez, M., Amezcua-Sanchez, J., Garcia-Perez, A., & Camarena-Martinez, D. (2019). Complete ensemble empirical mode decomposition on fpga for condition monitoring of broken bars in induction motors. *Mathematics*, 7(9), 783. <https://doi.org/10.3390/math7090783>
- Vincent, C., Giebel, G., Pinson, P., & Madsen, H. (2010). Resolving nonstationary spectral information in wind speed time series using the hilbert–huang transform. *Journal of Applied Meteorology and Climatology*, 49(2), 253-267. <https://doi.org/10.1175/2009jamec2058.1>
- Vo, H., Lee, G., Yang, H., Oh, I., Kim, S., & Kang, S. (2021). Survival prediction of lung cancer using small-size clinical data with a multiple task variational autoencoder. *Electronics*, 10(12), 1396. <https://doi.org/10.3390/electronics10121396>
- Wallcraft, A., Kara, A., Barron, C., Metzger, E., Pauley, R., & Bourassa, M. (2009). Comparisons of monthly mean 10 m wind speeds from satellites and NWP products over the global ocean. *Journal of Geophysical Research Atmospheres*, 114(D16). <https://doi.org/10.1029/2008jd011696>
- Wang, C., Liu, Z., Wei, H., Chen, L., & Zhang, H. (2021). Hybrid deep learning model for short-term wind speed forecasting based on time series decomposition and gated recurrent unit. *Complex System Modeling and Simulation*, 1(4), 308-321. <https://doi.org/10.23919/csms.2021.0026>
- Wang, F., Zeng, H., Liu, W., & Qin, J. (2020). A new prediction method of wind power based on l2 norm cloud to erase the wind uncertainty. *Ieee Access*, 1-1. <https://doi.org/10.1109/access.2020.2987938>
- Wang, G., Guo, L., & Duan, H. (2013). Wavelet neural network using multiple wavelet functions in target threat assessment. *The Scientific World Journal*, 2013, 1-7. <https://doi.org/10.1155/2013/632437>

- Wang, H., Han, S., Liu, Y., & Lin, A. (2020). Evaluation method of wind speed time-shifting characteristics at multiple scales and its application in wind power system. *Mathematical Problems in Engineering*, 2020, 1-17. <https://doi.org/10.1155/2020/4057630>
- Wang, J., Jiang, H., Han, B., & Zhou, Q. (2015). An experimental investigation of fnn model for wind speed forecasting using eemd and cs. *Mathematical Problems in Engineering*, 2015, 1-13. <https://doi.org/10.1155/2015/464153>
- Wang, K., Chang, H., Hsu, C., Chen, K., Hsieh, J., Li, L., ... & Shiao, A. (2015). Extractions of steady-state auditory evoked fields in normal subjects and tinnitus patients using complementary ensemble empirical mode decomposition. *Biomedical Engineering Online*, 14(1). <https://doi.org/10.1186/s12938-015-0062-0>
- Wang, S., Zhang, N., Wu, L., & Wang, Y. (2016). Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and ga-bp neural network method. *Renewable Energy*, 94, 629-636. <https://doi.org/10.1016/j.renene.2016.03.103>
- Wang, T. (2021). A combined model for short-term wind speed forecasting based on empirical mode decomposition, feature selection, support vector regression and cross-validated lasso. *Peerj Computer Science*, 7, e732. <https://doi.org/10.7717/peerj-cs.732>
- Wang, Y., Wang, Z., Yin, X., Zhu, C. (2019). Dropout in testing phase makes adversarial samples generation difficult. *Proceedings of 2019 the 9th International Workshop on Computer Science and Engineering*, 117-123. <https://doi.org/10.18178/wcse.2019.06.017>
- Wang, Z., Zhang, J., Zhang, Y., Huang, C., & Wang, L. (2020). Short-term wind speed forecasting based on information of neighboring wind farms. *Ieee Access*, 8, 16760-16770. <https://doi.org/10.1109/access.2020.2966268>
- Wanninkhof, R. (1992). Relationship between wind speed and gas exchange over the ocean. *Journal of Geophysical Research Atmospheres*, 97(C5), 7373. <https://doi.org/10.1029/92jc00188>
- Winstral, A., Marks, D., & Gurney, R. (2009). An efficient method for distributing wind speeds over heterogeneous terrain. *Hydrological Processes*, 23(17), 2526-2535. <https://doi.org/10.1002/hyp.7141>
- Wu, J., Ye, W., Lin, J., Zhang, X., Zeng, B., Fan, Y., ... & Chen, H. (2022). Temperature regulated artificial neuron based on memristor. *Ieee Electron Device Letters*, 43(11), 2001-2004. <https://doi.org/10.1109/led.2022.3206796>
- Wu, Z. and Huang, N. (2009). Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 01(01), 1-41. <https://doi.org/10.1142/s1793536909000047>
- Wu, Z., Jiang, C., Conde, M., Deng, B., & Chen, J. (2019). Hybrid improved empirical mode decomposition and bp neural network model for the prediction of sea surface temperature. *Ocean Science*, 15(2), 349-360. <https://doi.org/10.5194/os-15-349-2019>
- Xia, X. and Wang, X. (2022). A novel hybrid model for short-term wind speed forecasting based on twice decomposition, psr, and imvo-elm. *Complexity*, 2022, 1-21. <https://doi.org/10.1155/2022/4014048>
- Xiao, C., Li, B., Zhu, J., He, W., Liu, M., & Song, D. (2018). Generating adversarial examples with adversarial networks. *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, 3905-3911. <https://doi.org/10.24963/ijcai.2018/543>

- Xiao, D., Chen, Y., & Li, D. (2021). One-dimensional deep learning architecture for fast fluorescence lifetime imaging. *Ieee Journal of Selected Topics in Quantum Electronics*, 27(4), 1-10. <https://doi.org/10.1109/jstqe.2021.3049349>
- Xie, J., Zhang, H., Liu, L., Li, M., & Su, Y. (2021). Decomposition-based multistep sea wind speed forecasting using stacked gated recurrent unit improved by residual connections. *Complexity*, 2021, 1-14. <https://doi.org/10.1155/2021/2727218>
- Xing, L., Udemba, E., Tosun, M., Abdallah, I., & Boukhris, I. (2023). Sustainable development policies of renewable energy and technological innovation toward climate and sustainable development goals. *Sustainable Development*, 31(2), 1178-1192. <https://doi.org/10.1002/sd.2514>
- Xu, D., Ding, Y., Liu, H., Zhang, Q., & Zhang, D. (2022). Applicability of a ceemd–arima combined model for drought forecasting: a case study in the ningxia hui autonomous region. *Atmosphere*, 13(7), 1109. <https://doi.org/10.3390/atmos13071109>
- Xu, J., Huang, C., Cao, W., & Wu, Y. (2022). Torque ripple control strategy of switched reluctance motor based on bp neural network. *Journal of Physics Conference Series*, 2242(1), 012036. <https://doi.org/10.1088/1742-6596/2242/1/012036>
- Xu, Y. and Yang, G. (2020). A short-term wind speed forecasting hybrid model based on empirical mode decomposition and multiple kernel learning. *Complexity*, 2020, 1-13. <https://doi.org/10.1155/2020/8811407>
- Yamashita, R., Nishio, M., Gian, R., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights Into Imaging*, 9(4), 611-629. <https://doi.org/10.1007/s13244-018-0639-9>
- Yang, H., Jiang, Z., & Lu, H. (2017). A hybrid wind speed forecasting system based on a ‘decomposition and ensemble’ strategy and fuzzy time series. *Energies*, 10(9), 1422. <https://doi.org/10.3390/en10091422>
- Yang, S., Jin, A., & Xu, Y. (2021). Recognition of oil and gas reservoir space based on deep learning. *E3s Web of Conferences*, 267, 01038. <https://doi.org/10.1051/e3sconf/202126701038>
- Yang, Y. and Yang, Y. (2020). Hybrid prediction method for wind speed combining ensemble empirical mode decomposition and bayesian ridge regression. *Ieee Access*, 8, 71206-71218. <https://doi.org/10.1109/access.2020.2984020>
- Yeh, J., Shieh, J., & Huang, N. (2010). Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method. *Advances in Adaptive Data Analysis*, 02(02), 135-156. <https://doi.org/10.1142/s1793536910000422>
- You, H., Bai, S., Wang, R., Li, Z., Xiang, S., & Huang, F. (2022). New pso-svm short-term wind power forecasting algorithm based on the ceemdan model. *Journal of Electrical and Computer Engineering*, 2022, 1-9. <https://doi.org/10.1155/2022/7161445>
- Yusmartato, Y., Lubis, Z., Arza, S., Pelawi, Z., Armansah, A., Hasibuan, A., ... & Asaad, M. (2018). New method for locker door with face security system using backpropagation algorithm. *International Journal of Engineering & Technology*, 7(2.13), 402. <https://doi.org/10.14419/ijet.v7i2.13.16931>
- Zhang, G., Xu, B., Liu, H., Hou, J., & Zhang, J. (2021). Wind power prediction based on variational mode decomposition and feature selection. *Journal of Modern Power Systems and Clean Energy*, 9(6), 1520-1529. <https://doi.org/10.35833/mpce.2020.000205>
- Zhang, K., Li, X., & Su, J. (2022). Variable support segment-based short-term wind speed forecasting. *Energies*, 15(11), 4067. <https://doi.org/10.3390/en15114067>


- Zhang, K., Zhi, Q., Wang, J., Zhang, W., & Yang, F. (2017). A novel hybrid approach based on cuckoo search optimization algorithm for short-term wind speed forecasting. *Environmental Progress & Sustainable Energy*, 36(3), 943-952. <https://doi.org/10.1002/ep.12533>
- Zhang, L., Dong, Y., & Wang, J. (2019). Wind speed forecasting using a two-stage forecasting system with an error correcting and nonlinear ensemble strategy. *IEEE Access*, 7, 176000-176023. <https://doi.org/10.1109/access.2019.2957174>
- Zhang, L., Meng, K., Jia, Y., Ma, J., & Hai, R. (2020). A multistep wind speed forecasting system considering double time series features. *Ieee Access*, 8, 161018-161030. <https://doi.org/10.1109/access.2020.3021198>
- Zhang, X., Duan, B., He, S., Wu, X., & Zhao, D. (2022). A new precipitation forecast method based on ceemd-wtd-gru. *Water Science & Technology Water Supply*, 22(4), 4120-4132. <https://doi.org/10.2166/ws.2022.037>
- Zhang, Z., Cheng, H., Chen, X., & Ma, C. (2016). Frequency-specific alterations of functional hub in generalized tonic-clonic seizure. *International Journal of Networked and Distributed Computing*, 4(4), 221. <https://doi.org/10.2991/ijndc.2016.4.4.3>
- Zhao, F., Xue, M., Tao, T., Jiang, G., & Zhou, Y. (2011). Fault diagnosis of a machine tool rotary axis based on a motor current test and the ensemble empirical mode decomposition method. *Proceedings of the Institution of Mechanical Engineers Part C Journal of Mechanical Engineering Science*, 225(5), 1121-1129. <https://doi.org/10.1177/09544062jmes2368>
- Zhao, J., Cai, R., & Fan, Y. (2019). Prediction of sea level nonlinear trends around shandong peninsula from satellite altimetry. *Sensors*, 19(21), 4770. <https://doi.org/10.3390/s19214770>
- Zhao, L. and Qamruzzaman, M. (2022). Do urbanization, remittances, and globalization matter for energy consumption in belt and road countries: evidence from renewable and non-renewable energy consumption. *Frontiers in Environmental Science*, 10. <https://doi.org/10.3389/fenvs.2022.930728>
- Zhao, W., Wang, Z., Ma, J., & Li, L. (2016). Fault diagnosis of a hydraulic pump based on the ceemd-stft time-frequency entropy method and multiclass svm classifier. *Shock and Vibration*, 2016, 1-8. <https://doi.org/10.1155/2016/2609856>
- Zhao, X., Lin, Z., Tong, Y., Qi, Y., & Shi, J. (2021). Robust sound source localization using convolutional neural network based on microphone array. *Intelligent Automation & Soft Computing*, 29(3), 361-371. <https://doi.org/10.32604/iasc.2021.018823>
- Zhao, X., Wei, H., Li, C., & Zhang, K. (2020). A hybrid nonlinear forecasting strategy for short-term wind speed. *Energies*, 13(7), 1596. <https://doi.org/10.3390/en13071596>
- Zhao, Y., Guo, Z., & Yan, J. (2017). Vibration signal analysis and fault diagnosis of bogies of the high-speed train based on deep neural networks. *Journal of Vibroengineering*, 19(4), 2456-2474. <https://doi.org/10.21595/jve.2017.17238>
- Zhi, Q., Zhang, K., Wang, J., Zhang, W., & Leng, W. (2016). A hybrid model based on ensemble empirical mode decomposition and fruit fly optimization algorithm for wind speed forecasting. *Advances in Meteorology*, 2016, 1-14. <https://doi.org/10.1155/2016/3768242>
- Zhiwen, Z., Duan, F., Solé-Casals, J., Dinarès-Ferran, J., Cichocki, A., & Yang, Z. (2019). A novel deep learning approach with data augmentation to classify motor imagery signals. *Ieee Access*, 7, 15945-15954. <https://doi.org/10.1109/access.2019.2895133>

- Zhong, Y., Hao, J., Liao, R., Jiang, X., & Wang, F. (2020). Mechanical defect identification for gas-insulated switchgear equipment based on time-frequency vibration signal analysis. *High Voltage*, 6(3), 531-542. <https://doi.org/10.1049/hve2.12056>
- Zhou, J., Liu, H., Xu, Y., & Jiang, W. (2018). A hybrid framework for short term multi-step wind speed forecasting based on variational model decomposition and convolutional neural network. *Energies*, 11(9), 2292. <https://doi.org/10.3390/en11092292>
- Zhou, Z. (2023). An optimal configuration model for supercapacitor capacity to suppress wind power fluctuations. *Journal of Physics Conference Series*, 2588(1), 012013. <https://doi.org/10.1088/1742-6596/2588/1/012013>
- Zhu, T. (2022). Short-term wind speed prediction based on feemd-pe-ssa-bp.. <https://doi.org/10.21203/rs.3.rs-1425821/v1>
- Казанферович, А. and Churakov, P. (2015). Noise-robust speech signals processing for the voice control system based on the complementary ensemble empirical mode decomposition.. <https://doi.org/10.1109/sibcon.2015.7146972>




7. EKLER


EK 1: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve CEEMDAN+VMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları




Şekil 7.1. 1 Ocak 2020 tarihine ait basınç verisinin CEEMDAN + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri




Şekil 7.2. 1 Ocak 2020 tarihine ait sıcaklık verisinin CEEMDAN + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri




Şekil 7.3. 1 Ocak 2020 tarihine ait nem verisinin CEEMDAN + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri




Şekil 7.4. 1 Ocak 2020 tarihine ait basınç verisinin CEEMDAN + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri



Şekil 7.5. 1 Ocak 2020 tarihine ait sıcaklık verisinin CEEMDAN + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.6. 1 Ocak 2020 tarihine ait nem verisinin CEEMDAN + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.7. 1 Ocak 2020 tarihine ait CEEMDAN + VMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini


EK 2: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve EEMD+VMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları




Şekil 7.8. 1 Ocak 2020 tarihine ait basınç verisinin EEMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri




Şekil 7.9. 1 Ocak 2020 tarihine ait sıcaklık verisinin EEMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri




Şekil 7.10. 1 Ocak 2020 tarihine ait nem verisinin EEMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri




Şekil 7.11. 1 Ocak 2020 tarihine ait basınç verisinin EEMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri



Şekil 7.12. 1 Ocak 2020 tarihine ait sıcaklık verisinin EEMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.13. 1 Ocak 2020 tarihine ait nem verisinin EEMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.14. 1 Ocak 2020 tarihine ait EEMD + VMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini


EK 3: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve LMD+EEMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları




Şekil 7.15. 1 Ocak 2020 tarihine ait basınç verisinin LMD + EEMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.16. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + EEMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.17. 1 Ocak 2020 tarihine ait nem verisinin LMD + EEMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.18. 1 Ocak 2020 tarihine ait basınç verisinin LMD + EEMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri



Şekil 7.19. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + EEMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.20. 1 Ocak 2020 tarihine ait nem verisinin LMD + EEMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.21. 1 Ocak 2020 tarihine ait LMD + EEMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini


EK 4: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve LMD+LMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları




Şekil 7.22. 1 Ocak 2020 tarihine ait basınç verisinin LMD + LMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.23. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + LMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.24. 1 Ocak 2020 tarihine ait nem verisinin LMD + LMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.25. 1 Ocak 2020 tarihine ait basınç verisinin LMD + LMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri



Şekil 7.26. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + LMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.27. 1 Ocak 2020 tarihine ait nem verisinin LMD + LMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.28. 1 Ocak 2020 tarihine ait LMD + LMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini


EK 5: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve LMD+VMD+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları




Şekil 7.29. 1 Ocak 2020 tarihine ait basınç verisinin LMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.30. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.31. 1 Ocak 2020 tarihine ait nem verisinin LMD + VMD ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.32. 1 Ocak 2020 tarihine ait basınç verisinin LMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri



Şekil 7.33. 1 Ocak 2020 tarihine ait sıcaklık verisinin LMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.34. 1 Ocak 2020 tarihine ait nem verisinin LMD + VMD ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen üretim fonksiyonu bileşenleri




Şekil 7.35. 1 Ocak 2020 tarihine ait LMD + VMD + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini


EK 6: 1 Ocak 2020 tarihine ait atmosferik verilerin ayrıştırma yapılan bileşenleri ve VMD+CEEMDAN+SLOG2 tahmincisi ile yapılan 40m yükseklikli rüzgar hızı tahmin sonuçları




Şekil 7.36. 1 Ocak 2020 tarihine ait basınç verisinin VMD + CEEMDAN ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.37. 1 Ocak 2020 tarihine ait sıcaklık verisinin VMD + CEEMDAN ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.38. 1 Ocak 2020 tarihine ait nem verisinin VMD + CEEMDAN ayrıştırma modeline göre birincil ayrıştırma işlemi sonucu elde edilen Mod bileşenleri




Şekil 7.39. 1 Ocak 2020 tarihine ait basınç verisinin VMD + CEEMDAN ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri



Şekil 7.40. 1 Ocak 2020 tarihine ait sıcaklık verisinin VMD + CEEMDAN ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri



Şekil 7.41. 1 Ocak 2020 tarihine ait nem verisinin VMD + CEEMDAN ayrıştırma modeline göre ikincil ayrıştırma işlemi sonucu elde edilen IMF bileşenleri



Şekil 7.42. 1 Ocak 2020 tarihine ait VMD + CEEMDAN + SLOG2 tahminci ile yapılan 40m yükseklikli rüzgar hızı tahmini