

T.C.
BİNGÖL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA YÖNTEMLERİ İLE RÜZGAR TAHMİNİ

YÜKSEK LİSANS TEZİ

FATİH KARAASLAN

YENİLENEBİLİR ENERJİ SİSTEMLERİ

TEZ DANIŞMANI
Doç. Dr. Muzaffer ASLAN

BİNGÖL-2024

YAPAY ZEKA YÖNTEMLERİ İLE RÜZGAR TAHMİNİ

Doç. Dr. Muzaffer ASLAN danışmanlığında, Fatih KARAASLAN tarafından hazırlanan bu çalışma 27/08/2024 tarihinde aşağıdaki jüri tarafından Yenilenebilir Enerji Sistemleri Anabilim Dalı'nda Yüksek Lisans Tezi olarak **oybirliği** ile kabul edilmiştir.

Başkan : Doç. Dr. Abdulkerim KARABİBER *İmza* :
Üye : Doç. Dr. Ömer Faruk ALÇİN *İmza* :
Üye : Doç. Dr. Muzaffer ASLAN *İmza* :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulunun// tarih ve/
nolu kararı ile onaylanmıştır.

Prof. Dr. Zafer ŞİAR
Enstitü Müdürü

ÖNSÖZ

Tez çalışmalarımı yaptığım süre zarfı içerisinde bilgi ve birikimleri ile vermiş olduğu desteklerinden ve bilimsel bir çalışmanın esaslarını öğreten saygı değer danışmanın Doç. Dr. Muzaffer ASLAN' a ve desteklerinden ötürü Doç. Dr. Ömer Faruk ALÇİN hocamıza teşekkür ederim. Tez çalışmalarına desteklerinden ve katkılarından dolayı Elazığ Meteoroloji Bölge Müdürlüğüne teşekkür ederim.

Son olarak bugünlere gelmemde emeği olan aileme ve çalışmalarım sürecinde manevi olarak desteklerini esirgemeyen eşim Arzu KARAASLAN' a teşekkür ederim.

Fatih KARAASLAN

Bingöl 2024

İÇİNDEKİLER

ÖNSÖZ	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vii
ÖZET.....	viii
ABSTRACT.....	ix
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	5
3. RÜZGÂR ENERJİSİ	14
3.1. Enerji.....	14
3.1.1. Rüzgâr Enerjisi	15
3.1.2. Türkiye ve Dünyada Rüzgâr Enerjisinin Mevcut Durum Analizi	18
3.2. Rüzgâr Hızı Tahmin Yöntemleri	21
3.2.1. Sayısal Hava Tahmini ve Rüzgâr Tahmini	22
3.2.2. İstatiksel Hava Tahmin Modeli.....	22
3.2.2.1. Yapay Sinir Ağları İle Rüzgâr Hız Tahmini	23
3.2.2.2. Destek Vektör Makinesi İle Rüzgâr Hız Tahmini	24
3.2.2.3. Bulanık Mantık Yöntemi İle Rüzgâr Hız Tahmini	25
4. MATERYAL VE YÖNTEM	27
4.1. Yapay Zekâ	27
4.1.1. Yapay Sinir Ağları	28
4.1.1.1. Tek Katmanlı Algılayıcılar	30
4.1.1.2. Çok Katmanlı Algılayıcılar.....	31
4.1.1.3. İleri Beslemeli Yapay Sinir Ağları	32
4.1.1.4. Geri Beslemeli Yapay Sinir Ağları	33
4.2. Makine Öğrenimi	34
4.3. Derin Öğrenme	34
4.3.1. Evrişimli Sinir Ağı ve Katmanları	35
4.3.1.1. AlexNet.....	37
4.3.1.2. GoogleNet.....	39
4.3.1.3. ResNet50.....	40

4.3.1.4. Önerilen ESA Model Mimarisi.....	41
4.4. Transfer Öğrenimi.....	43
4.5. Sürekli Dalgacık Dönüşümü.....	44
4.6. Veri Seti.....	47
4.6.1. Veri Setinin Düzenlenmesi.....	48
4.7. Performans ve Değerlendirme Ölçütleri.....	48
5. BULGULAR VE TARTIŞMA.....	51
6. SONUÇLAR VE ÖNERİLER.....	62
KAYNAKLAR.....	63



SİMGELER VE KISALTMALAR LİSTESİ

YEK	: Yenilenebilir Enerji Kaynakları
KW	: Kilowatt
MW	: Megawatt
GW	: Gigawatt
REPA	: Rüzgâr Enerjisi Potansiyel Atlası
YZ	: Yapay Zekâ
YSA	: Yapay Sinir Ağı
ESA	: Evrişimli Sinir Ağı
TSA	: Tekrarlayan Sinir Ağı
ZEA	: Zamansal Evrişimli Ağ
UKSBA	: Uzun Kısa Süreli Bellek Ağları
GTB	: Geçitli Tekrarlayan Birimler
TKA	: Tek Katmanlı Algılayıcılar
ÇKA	: Çok Katmalı Algılayıcılar
SHT	: Sayısal Hava Tahmini
DVM	: Destek Vektör Makinesi
m	: Metre
SDD	: Sürekli Dalgacık Dönüşümü
VGG	: Çok Derin Evrişimli Ağlar

ŞEKİLLER LİSTESİ

Şekil 3.1. Enerji kaynakları ve gruplandırılmaları	14
Şekil 3.2. Üç kanatlı yatay eksenli bir rüzgâr türbinin şeması.....	16
Şekil 3.3. Yatay eksenli bir rüzgâr türbini gövdesindeki aktarma organlarının şeması ...	16
Şekil 3.4.Yıllara göre rüzgâr enerjisine dayalı kurulu güç.....	18
Şekil 3.5. Türkiye’de toplam kurulu güç içerisindeki oran.....	19
Şekil 3.6. Türkiye’deki Rüzgâr Santrallerinin Dağılımı	20
Şekil 3.7. Dünya toplam rüzgâr kurulum kapasitelerinin tarihsel gelişimi.....	21
Şekil 4.1. İleri beslemeli çok katmanlı bir yapay sinir ağı yapısı.....	29
Şekil 4.2. Tek katmanlı algılayıcı	30
Şekil 4.3. İleri beslemeli YSA yapısı	32
Şekil 4.4. Geri beslemeli YSA yapısı.....	33
Şekil 4.5. Evrişimli sinir ağı katmanları.....	35
Şekil 4.6. AlexNet ağ mimarisi	38
Şekil 4.7. GoogleNet modeli ağ mimarisi	40
Şekil 4.8. ResNet50 modelinin mimari yapısı	41
Şekil 4.9. Tasarlanan ağın mimarisi	42
Şekil 4.10. Transfer öğrenimi.....	44
Şekil 4.11 Sürekli dalgacık dönüşümü.....	45
Şekil 4.12. Elazığ iline ait ham rüzgâr verileri.....	47
Şekil 4.13. Elazığ iline ait düzenlenmiş rüzgâr verileri	48
Şekil 5.1. Önerilen model genel yapısı.....	51
Şekil 5.2. Zaman serilerinden scalogram görüntülerin elde edilmesi	52
Şekil 5.3. AlexNet 1 saatlik orijinal sonuçlar	55
Şekil 5.4.AlexNet 1 saatlik normalize edilmiş sonuçlar	55
Şekil 5.5. GoogleNet 1 saatlik orijinal sonuçlar	56
Şekil 5.6. GoogleNet 1 saatlik normalize edilmiş sonuçlar	56
Şekil 5.7. ResNet50 1 saatlik orijinal sonuçlar	57
Şekil 5.8. Resnet50 1 saatlik normalize edilmiş sonuçlar	57

Şekil 5.9.Önerilen model 1 saatlik orijinal sonuçlar	58
Şekil 5.10. Önerilen model 1 saatlik normalize edilmiş sonuçlar	58
Şekil 5.11. Önerilen model 2 saatlik orijinal sonuçlar	59
Şekil 5.12. Önerilen model 2 saatlik normalize edilmiş sonuçlar	59
Şekil 5.13.Önerilen model 3 saatlik orijinal sonuçlar	60
Şekil 5.14. Önerilen model 3 saatlik normalize edilmiş sonuçlar	60



TABLolar LİSTESİ

Tablo 3.1. İncelenen bazı rüzgâr hızı tahmin modelleri.....	24
Tablo 4.1. Tasarlanan ağın ayrıntılı katman konfigürasyonu	43
Tablo 5.1.Tahmin sonuçları	53



YAPAY ZEKA YÖNTEMLERİ İLE RÜZGAR TAHMİNİ

ÖZET

Gelişmiş ve gelişmekte olan ülkelerde son yıllarda, elektrik enerji taleplerinin karşılanmasında yenilenebilir enerji kaynakları tercih edilmektedir. Rüzgâr enerjisi, bu enerji kaynakları arasında daha verimli olmasından dolayı yaygın olarak kullanılmaktadır. Bununla birlikte, rüzgâr enerjisi güç sistemlerinin yönetilmesi ve işletilmesinde rüzgâr hızını doğru ve güvenilir bir şekilde tahmin edilmesi oldukça önemlidir. Ancak, rüzgâr hızının aralıklı ve durağan olmayan yapısı nedeniyle, onun modellenmesi ve tahmin edilmesini zorlaştırmaktadır.

Bu çalışmada, rüzgâr santrallerinin planlanması ve uygulanabilirlik çalışmaları için etkili bir rüzgâr tahmini için derin öğrenme temelli iki aşamalı bir model önerildi. Bu yaklaşımda öncelikle rüzgâr hız zaman verileri, sürekli dalgacık dönüşümü ile renkli görüntüye dönüştürüldü. Daha sonra bu görüntüler önerilen evrişimli sinir ağı yardımıyla etkili bir rüzgâr tahmini gerçekleştirildi. Çalışmada, Elazığ Metroloji Bölge Müdürlüğünden alınan 2018-2019 yılları arasındaki saatlik rüzgâr hız verileri kullanılmıştır. Deneysel çalışmalarda, 1-saat, 2-saat ve 3-saat olmak üzere üç farklı ileri ufuk tahmini yapılmıştır. Önerilen modelin performans değerlendirilmesinde ortalama karekök hatası (RMSE), ortalama mutlak hata (MAE) ve korelasyon katsayısı (R) metrikleri kullanılmıştır. Deneysel çalışma sonuçlarına göre 1 saatlik ileri tahminlerde RMSE, R ve MAE performans değerlendirme ölçütlerinde sırasıyla 0,0615, 0,8757 ve 0,0448 başarımlar sağlanırken, 2 saatlik ileri tahminlerde RMSE, R ve MAE metriklerinde sırasıyla 0,0804, 0,7397 ve 0,0590 başarımların 1-saatlik ileri tahminlere göre biraz azaldığı görülmektedir. Bu durum 3-saatlik ileri tahminlerde de devamı görüldü. Tüm bu deneysel sonuçlar önerilen modelin kısa tahmin dönemleri için daha iyi bir tahmin performansı sergilediğini göstermektedir. Ayrıca daha detaylı performans analiz için AlexNet, ResNet50 ve GoogLeNet gibi 3 farklı derin öğrenme model sonuçları ile karşılaştırılmasında 1 saatlik ileri tahminde daha başarılı olduğu görülmüştür.

Anahtar Kelimeler: Rüzgâr Enerjisi Tahmini, Sürekli Dalgacık Dönüşümü, Evrişimli Sinir Ağı, Derin Öğrenme.

WIND PREDICTION WITH ARTIFICIAL INTELLIGENCE METHODS

ABSTRACT

In recent years, renewable energy sources have been preferred for meeting electricity demands in developed and developing countries. Wind energy is widely used among these energy sources because it is more efficient. However, accurately and reliably predicting wind speed is very important in the management and operation of wind energy power systems. Due to the intermittent and non-stationary nature of wind speed, modeling and predicting it becomes challenging.

In this study, a deep learning-based two-stage model is proposed for effective wind forecasting for the planning and feasibility studies of wind farms. In this approach, firstly, wind speed time data was converted into color images using continuous wavelet transform. Then, effective wind forecasting was performed using these images with the help of the proposed convolutional neural network. The study utilized hourly wind speed data from 2018 to 2019 obtained from the Elazığ Meteorology Regional Directorate. In the experimental studies, three different forward horizon predictions were made: 1-hour, 2-hour, and 3-hour forecasts. Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and correlation coefficient (R) metrics were used for performance evaluation of the proposed model. According to the experimental results, in 1-hour ahead predictions, successes of 0.0615, 0.8757, and 0.0448 were achieved in RMSE, R, and MAE performance evaluation criteria, respectively. In 2-hour ahead predictions, it was observed that the performances in RMSE, R, and MAE metrics slightly decreased compared to the 1-hour ahead predictions, with values of 0.0804, 0.7397, and 0.0590, respectively. This trend continued in the 3-hour ahead predictions as well. All these experimental results show that the proposed model exhibits better prediction performance for shorter forecast periods. Additionally, for more detailed performance analysis, it was seen that the proposed model was more successful in the 1-hour ahead prediction when compared with the results of three different deep learning models like AlexNet, ResNet50, and GoogLeNet.

Keywords: Wind Energy Forecasting, Continuous Wavelet Transform, Convolutional Neural Network, Deep Learning.

1. GİRİŞ

Dünya çapında; nüfus artışları, teknolojik ve ekonomik gelişmelerin sürekli bir şekilde devam etmesine bağlı olarak enerji tüketimi de önemli ölçüde artış göstermektedir. Enerji taleplerinin ve kirlenici emisyonların artmasıyla birlikte İklim değişikliklerinin etkileri ve sürdürülebilir bir enerji geleceği dikkate alındığında çevre dostu yeni enerji kaynakları arayışına başlanılmıştır [1].

Enerjinin; mekanik enerji, kimyasal enerji, nükleer enerji ve elektrik enerjisi gibi çeşitleri bulunmaktadır. Günlük yaşantımızda en çok kullandığımız enerji türü elektrik enerjisi olduğu bilinmektedir. Son yıllarda gerek ülkemizde gerekse dünya genelinde elektrik enerjisi tüketiminde büyük artışlar görülmeye başlanmıştır. Elektrik tüketimine karşılık olarak yapılacak olan üretiminin düşük karbonlu bir şekilde gerçekleşmesi, iklim değişikliğiyle mücadele ve gelecekteki enerji arzını sağlamak açısından oldukça önemlidir. Bu açıdan Yenilenebilir Enerji kaynakları (YEK) gelecekteki enerji üretimi için sürdürülemez kaynaklara alternatif ve çevreci olmaları nedeniyle kullanımları hızla artmaktadır. Temel olarak yenilenebilir enerji kaynakları; biokütle ve biyogaz, jeotermal enerji, hidroelektrik, fotovoltaik, rüzgâr enerjisi olarak sıralanmaktadır. Bu kaynaklar arasında en çok hidroelektrik, fotovoltaik (güneş enerjisi) ve rüzgâr enerjisi tercih edilmekte olup coğrafi konumlara göre değişiklik göstermektedir [2]. Düşük karbonlu üretim teknolojileri arasında, rüzgâr enerjisini geliştirme, birçok ülke tarafından ön planda tutulmuştur [3]. Yenilenebilir enerji kaynakları arasında daha fazla ilgi gören rüzgâr enerjisi kirlilik içermeyen ve yaygın olarak dağıtılmış bir enerji kaynağıdır.

Rüzgâr enerjisinden elektrik elde edebilmek rüzgâr türbinleri ile mümkündür. Bunun içinde Rüzgâr Enerji Santralleri (RES) kurulmuştur. Yatay eksenli rüzgâr türbinleri ve dikey eksenli rüzgâr türbinleri olmak üzere iki çeşit rüzgâr türbinini bulunmaktadır. Bunlar içerisinde en çok dikey eksenli rüzgâr türbinleri tercih edilmektedir. Ancak yatay eksenli rüzgâr türbinleri rüzgârın yönüne yöneldiğinde dikey eksenli rüzgâr türbinlerine göre daha yüksek verimlilikte çalışırlar [4].

RES'lerde güç üretimi tahmini yapabilmek için önem arz etmekte olan rüzgâr hızı, rüzgâr yönü, ışınımı ve diğer önemli özelliklerini bulabilmek için mekânsal ve iklimsel veriler oldukça önemlidir.

Temiz ve emisjonsuz olması, emisyonu olmadığı için sera gazı oluşturmaması gibi avantajları bulunan rüzgâr enerjisinin avantajları ile birlikte yatırım maliyetlerinin yüksek olması gibi dezavantajları da bulunmaktadır. Rüzgâr ve enerji talebindeki dalgalanmalar nedeniyle RES'ler alternatif yükler altında karmaşık koşullar altındadır. Kötü çalışma koşullarının performans düşüşüne, rüzgâr türbinlerinin rüzgâr çıktısının azalmasına, işletme ve bakım maliyetlerinin olması gibi nedenler dikkate alındığında rüzgâr türbinlerinin güvenilir bir şekilde çalışmasını sağlamak için doğru performans çok önemlidir [5]. Ayrıca kurulum stratejisi, enerji yakalamayı optimize ederken türbinler ile tüketim alanları arasındaki uzun mesafeler nedeniyle artan elektrik iletim kayıpları ve uzak konumları gibi nedenlerden dolayı zorluklar ortaya çıkmaktadır [4]. Bu nedenle rüzgâr türbinleri kurulmadan önce o bölgenin rüzgâr hızı potansiyellerini incelemek oldukça önemlidir. Bunun için Meteoroloji Genel Müdürlükleri tarafından kurulan rüzgâr gözlem istasyonlarından alınan veriler kullanılarak RES'lerin kurulacağı bölgelerin rüzgâr hız potansiyelini incelemek gereklidir.

Çalışmamızın hedefi yenilenebilir enerjinin dünya çapında ve ülkemiz genelinde bu kadar önemli olduğu son zamanlarda, yapay zekânın uygulama alanlarını içerisine olan derin öğrenme yöntemleri ile rüzgâr tahmini yaparak rüzgâr enerji potansiyeli incelemesi yapmaktır.

Birçok bilim adamı, özellikle rüzgâr ve güneş enerjileri gibi sistemlerinin kurulumunun planlanması ve verimliği gibi kaynakları tahmin etmek için son derece hassas sistemler inşa etmek için çalışmalar yapmış ve halen daha bu çalışmalara devam edilmektedir. Son yıllarda, rüzgâr tahmini üzerinde: tahmin dönemine göre; çok kısa vadeli, kısa vadeli, orta vadeli ve uzun vadeli tahminler olmak üzere dört kategori, kullanılan yöntemlere göre ise; fiziksel yöntemler, geleneksel istatistiksel yöntemler ve yapay zekâ (YZ) tabanlı yöntemler üzerinde araştırmalar ve çalışmalar yapılmıştır. Fiziksel yöntemler, orta vadeli ve uzun vadeli tahminlerde iyi performanslar göstermiştir, ancak kısa vadeli tahminler için aynı şeyleri söylemek mümkün değildir, ayrıca zaman almaktadır. Geleneksel yöntemler ise

kararsız sinyaller ve performanslarında düşüş gösterdikleri için arařtırmacılar tarafından tercih edilmemektedir. Arařtırmacılar Fiziksel ve Geleneksel yöntemler yerine doğrusal olmayana çözüme konusunda güçlü bir yeteneğe sahip yapay zekâ modelini tercih etmektedir. Yapay sinir aęları (YSA), herhangi bir ön bilgi sahibi olmadan geçmiş verilerden kuralları doğrudan öğrenebilen ve uygulamada yüksek performanlara sahiptir. YZ tabanlı yöntemler temel olarak destek vektör makinesi, tam baęlı sinir aęı, evriřimli sinir aęı (ESA), uzun kısa süreli bellek aęları (UKSBA), çift yönlü uzun kısa süreli bellekten oluşmaktadır. Farklı ölçeklerde bilgi çıkarma özelliğine sahip olan ESA, özellik ayıklamada güçlü yeteneklere sahiptir, ancak uzun vadeli baęımlılıkları göz ardı edebilmektedir [6].

Bu kapsamda çalışmamızda, Meteoroloji 13. Bölge Müdürlüğünden Elazığ iline ait rüzgâr hızı verilerini alarak, yapay zekâ ve derin öğrenme modelleri ile Elazığ ilinin rüzgâr potansiyeli hakkında tahminde bulunmaktadır. Deneysel çalışma sonuçlarına göre Elazığ ilinin RES kurulumu için uygun olup olmadığını incelenecektir.

Yapılan literatür taramasına göre Elazığ iline ait rüzgar gücü potansiyeli incelemesiyle ilgili E.Kavak Akpınar ve N.Balpetek “*Weibull ve Rayleigh dağılımlarına göre Elazığ ilinin rüzgar enerjisi potansiyelinin istatistiksel analizi*” başlıklı çalışmalarıyla 2005-2014 yılları arasında Meteoroloji Genel Müdürlüğü tarafından saatlik olarak ölçülen rüzgar hızı verileri ile Weibull ve Reyleigh dağılımlarını kullanarak Elazığ iline ait rüzgar gücü potansiyel incelemesi yapılmıştır. Çalışmamızı E.Kavak Akpınar ve N.Balpetek’in yapmış olduğu çalışmadan farklı kılan tarafı bu çalışmanın istatistiksel yöntemler kullanılarak yapılmış olması bizim çalışmamızın ise derin öğrenme yöntemlerinin kullanılarak yapılmasıdır.

Bu tez çalışması Giriş, Kaynak Özetleri, Rüzgâr Enerjisi Materyal Metot, Bulgular ve Tartışma, Sonuç ve Öneriler olmak üzere 6 bölümden oluşmaktadır;

Giriş bölümünde; enerji, enerji tüketiminin önemi, en çok tercih edilen elektrik enerjisi ve elektrik enerjisi üretiminde büyük bir ilgi gören ve çalışmamızın ana konusu olan rüzgâr enerjisi ve rüzgâr enerji santrallerine, yapay zekâ uygulamalarına değinilerek tezimizin amacı anlatılmaya çalışılmıştır.

Literatür taraması bölümünde; yapay sinir ağları ve derin öğrenme yöntemleri ile yapılmış olan rüzgâr hızı tahminlerine yer verilmiştir.

Rüzgâr enerjisi bölümünde; enerji, rüzgâr enerjisi ve rüzgâr türbinleri hakkında detaylı bilgilere yer verilmiştir Ayrıca rüzgâr hızı tahmin yöntemleri hakkında bilgi verilmiştir. Materyal ve metot bölümünde. Çalışmamızda kullanılan veri seti hakkında bilgilere yer verilmiş ve YZ ve alt uygulama alanlarından olan derin öğrenme yöntemler detaylandırılmıştır.

Bulgular ve tartışma bölümünde; rüzgâr hızı tahmini için yapmış olduğumuz deneysel çalışmalar ve bu çalışmalardan elde edilen deney sonuçları sunulmaktadır.

Sonuç ve öneriler bölümünde; yapılan deneysel çalışmalar sonucunda bulunan değerlerin karşılaştırılması yapılarak hangi modelin daha iyi bir performans sergilediğinden bahsedilmiştir.

2. KAYNAK ÖZETLERİ

Yapay zekânın uygulama alanlarını içerisine alan YSA ve derin öğrenme yöntemleri ile rüzgâr hız tahmini üzerinde yapılan çalışmalarda;

Guangzhao Chen ve diğerleri, tarihsel rüzgâr verilerine dayalı olarak fırtınaya yönelik derin öğrenme teknolojisini tanıtmıştır. Tek boyutlu evrişimli sinir ağ (1D-ESA), gök gürültülü fırtına işaretleriyle otomatik yüzey gözlem sisteminde bir dakikalık veri tabanından her 91 dakikada bir 76480 rüzgâr hızı ve yönü zaman serisi segmentine dayalı olarak eğitilmiştir. Veriler, uzunluğu 5 olan 24 çekirdekli ve uzunluğu 10 olan 48 çekirdekli iki konvolüsyonel katmanla, tek boyutlu ESA, üzerinde çalıştırılmış ve girdi verilerini fırtınalı veya fırtınasız duruma göre sınıflandırmak için uzunluğu 128 olan tam bağlı bir katman benimsenmiştir. Bunun sonucunda tek boyutlu ESA, fırtına olaylarını tanımak için başarılı bir örüntü tanıma yöntemi olma yeteneğine sahip olduğuna saptanmış ve buradan eğitilmiş tek boyutlu ESA için genel başarı oranı %86,7 olarak bulunmuştur. Bu çalışma aynı zamanda öğrenmeyi otomatik yüzey gözlem sistemi olmayan istasyonlara aktarma olasılığını da gösterir ve tepe rüzgâr eşiği ne kadar yüksek olursa ayırma doğruluğunun o kadar güvenilir olduğu bulunmuştur. Çalışmada ağın kafasını karıştıracak düşük sınırlama değerine sahip düşük rüzgâr hızlarına da yer verilmiş, ancak otomatikleştirilmiş sınıflandırma yönteminin iyileştirilmesine ihtiyaç duyulmuştur [7].

Ozsoy ve diğerleri, Türkiye’de rüzgâr enerjisi kurulu gücünü tahmin etmek için yapay sinir ağı kullanmıştır. Ağın eğitim ve simülasyon denemeleri arasından en iyi sonucu veren 3 girişli, tek çıkışlı ve bir gizli katmanı olan ileri beslemeli geriye yayımlı bir yapay sinir ağı ile MATLAB yazılımı tasarlanmıştır. 2016 yılında TEİAŞ tan alınan verilere göre Türkiye’de rüzgâr enerjisi kurulu gücü 5751,3 MW tır. Bu çalışmada ise % 4,53 sapma ile 6011,88 MW olarak tahminde bulunulmuştur. Çalışma kapsamında 2017 yılında ise 6277,39 MW tahminde bulunulmuş ancak çalışmanın yılı itibariyle 2017 yılına ait TEİAŞ verileri çalışmaya yansıtılmamıştır. Bu kapsamda yaptığım araştırmalar neticesinde 2017 yılına ait TEİAŞ verilerine göre Türkiye’de rüzgâr enerjisi kurulu gücü 6516,2 MW olarak kayıtlara girmiş böylece %3,65 sapma olduğu tespit edilmiştir [8].

Shubhi Harbolaa ve diğeri, rüzgâr hızını ve yönünün tahmin etmek için tek boyutlu tekli ESA ve tek boyutlu çoklu ESA önermişlerdir. Önerilen bu çalışmada rüzgâr hızı ve yönü bakımından girdi olarak ardışık zamansal değer alınmış ve girdideki son değerden sonra gelecek hâkim hız ve yönü ayrı ayrı tahmin edilmiştir. Çalışma geliştirilerek çoklu tek boyutlu ESA kullanılarak tek boyutlu ESA ile kıyaslandığında daha fazla bilgiye ulaşıldığı anlaşılmıştır. Bu çalışmadaki veriler Almanya ve Hollanda'nın tarihsel rüzgâr verilerinden farklı aylar kullanılarak alınmıştır. Önerilen tek boyutlu bir ESA; bir giriş katmanına, üç evrişim katmanına, iki tamamen bağlı katmana ve bir çıkış katmanına sahiptir. Giriş katmanı W_s boyutunda tek boyutludur. Tek boyutlu bir ESA katmanından hız ve yön olmak üzere iki özellik geçirilerek veri kümesinden ardışık W_s değerleri oluşur. Giriş katmanı, sırasıyla üç evrişim katmanını takip eder ve son evrişim katmanı tamamen bağlı katmanın ilkinine bağlıdır. Son olarak çıkış katmanı bulunmaktadır ve nöron sayısı, sınıf sayısı ile aynı olan bir katmandır. Bu çalışmada on bir sınıf kullanılmış ve bu sınıflar hız ve yön tahmini için ayrı ayrı eğitilmiş ve test edilmiştir. Hız ve yön tahmin etmek için tek boyutlu tekli ESA kullanıldığında doğruluk oranı Almanya için %90,2 ve %95,1 Hollanda için ise %95,2 ve %94,7 olarak bulunmuştur. Tek boyutlu çoklu ESA kullanıldığında ise doğruluk oranı Almanya için %96,8 ve %99,7 Hollanda için ise %98,8 ve %99,4 olarak bulunmuştur. Bu durumda;Almanya için tek boyutlu çoklu ESA, tek boyutlu tekli ESA ile kıyaslandığında doğruluk oranı aylara göre %6,3 (Mart) ve %8,4 (Haziran) şeklinde, Hollanda için tek boyutlu çoklu ESA, tek boyutlu tekli ESA ile kıyaslandığında doğruluk oranı aylara göre %7,3 (Mart) ve %6,9 (Haziran) şeklinde artış göstermiştir [9].

Zhenhao Gan ve diğeri, rüzgâr hızını tahmin etmek için zamansal evrişimli ağlarına (ZEA) dayanan yeni bir aralık tahmin modeli önermişlerdir. ZEA, nedensel kısıtlama ile dizi modelleme görevleri için önerilen genel evrişimli ağlar olarak bilinmektedir. Aralık tahmin modeli, zaman serilerinden özellik çıkarımı için bir ZEA girdi katmanı, birkaç tamamen bağlı katman ve daha düşük değerler elde etmek için uçtan uca sıralama katmanından oluşur. Modelin öğrenilebilmesi ve eğitim etiketlerinin tasarlanması için uyarlanabilir bir aralık oluşturma optimizasyon stratejisi ileri sürülmüştür. Yöntemi test etmek ve doğrulamak için iki rüzgâr alanından sekiz durum uygulanmıştır. Önerilen model ile son teknoloji modeller arasındaki tahmin doğruluğunu ve güvenilirliğini karşılamak için özel deneyler tasarlanmıştır. Öngörülen sonuçlar rüzgâr hız tahmininin etkinliğini ve doğruluğunu kanıtlamıştır. Zamansal Evrişimli Ağlar ve Tekrarlayan Sinir Ağları, arasında

ve farklı zamanlarda tahmin edilen deney sonuçları önerilen yöntemin etkinliğini daha da kanıtlamıştır. Dolayısıyla uyarlanabilir bir optimizasyon stratejisi tasarlayarak rüzgar hız tahmini için önerilen aralık tahmin modeli, tahmin aralıkları kalitesinde mütevazı bir ilerleme sağlayabilir ve karar vericilere rüzgar gücü dalgalanma riskini ölçmek ve start-stop planlarını geliştirmek için teorik bir temel sağlayabileceği belirtilmektedir [10].

Sergio ve diğerleri, Brezilya'nın Kuzey Doğu Bölgesinde Derin Öğrenme yöntemiyle iki gizli katman kullanarak rüzgâr hızını tahmini ile ilgili çalışma yapmışlardır. Bu çalışmada rastgele bir şebeke araması ile ağırlık giriş katmanındaki nöron sayısı, birinci katmandaki nöron sayısı, ikinci katmandaki nöron sayısı ve var olduğu varsayılan eğitim parametreleri değiştirilmiştir. Derin öğrenme yaklaşımlarının zaman serisi tahminlerinde kullanımını araştırmak için ilk olarak katmanların her biri bir otomatik kodlayıcı olarak kabul edilmiş ve yığın gürültü giderici otomatik kodlayıcılar olarak bilinen modeli karakterize eden giriş verilerine gürültü eklenmiştir. Sonrasında katmanların her biri derin inanç ağı olarak bilinen modeli karakterize eden kısıtlı Boltzmann makinesi olarak kabul edilmiştir. Parametrelerin nasıl seçildiğine bağlı olarak, bazı ağlar ön eğitim olmadan eğitilmiş ve ortak birçok katmanlı algılayıcı kabul edilmiştir. Buradaki amaç ön eğitimin yapıp yapılmayacağına değip değmeyeceği değerlendirmektir. Çalışmada derin inanç ağları en iyi performansı gösterirken, yığın gürültü giderici otomatik kodlayıcılar ise en kötü performansı sergilediği tespit edilmiştir [11].

Duan ve diğerleri, temiz bir enerji türü olan rüzgâr enerjisinin güç sistemleri üzerindeki etkilerine değinerek, rüzgâr hızının doğru tahmin edilmesinin elektrik şebekelerinin güvenliği açısından da önem arz ettiğini vurgulanmışlardır. Çalışmada ilk olarak orijinal rüzgâr hızı serisini bir dizi alt seriye ayrıştırmak için yeni bir ayrıştırma yaklaşımı kullanılmış, daha sonra tekrarlayan sinir ağı ile rüzgâr hızı tahmin edilmiş ve son olarak önceden tahmin edilen rüzgâr hızını düzeltmek için hata ayrıştırması yapılmıştır. Çalışmadaki hibrit modelin aslı rüzgâr hızı tahmininin doğruluğunu artırmak için hatayı tahmin etmek ve önceden tahmin edilen rüzgâr hızını, tahmin hatasını kullanarak düzeltmektir [12].

Ying-Yi Hong ve Diğerleri, görüntü tabanlı bir derin öğrenme yöntemi olan ESA' ya dayalı yeni bir gün öncesi zamansal rüzgâr hızı tahmin yöntemi önermişlerdir. Çalışmada yedi

bölgede (Tayvan, Çin, Kore ve Filipinler) tarihsel rüzgâr hızlarını kullanarak rüzgâr hızını 24 saat önceden tahmin edilebilmesi için iki boyutlu ESA yöntemi kullanılmıştır. ESA'nın parametreleri ve hiperparametreleri Taguchi yöntemiyle, deneme yanılma olmaksızın belirlenmiştir. Taguchi yöntemi; mühendislikte tasarım süreçlerini optimize etmek için kullanılan sağlam bir tasarım yöntemidir. Burada parametreler her bir katmandaki kıvrımların sayısını kademeli katmanların sayısını ve tamamen bağlı ağdaki gizli katmanların sayısıdır. Hiperparametreler ise çekirdek sayısı, çekirdek boyutu sıfır doldurma ve bırakma oranıdır. Cümlemizin başında da belirtildiği gibi çalışmada girdi olarak Tayvan, Çin, Güney Kore ve Filipinlerdeki yedi bölgeden alınan rüzgâr hız verileri, çıktı olarak ise çalışılan tahmin problemlerinde elde edilen değerler ve performans endeksleri kullanılmıştır. Çalışmanın deneysel adımları;

- Rüzgâr türbinlerinin göbeklerindeki ortalama rüzgâr hızları tahmin edilir,
- Ortalama rüzgâr hızı 24 km/s olarak geniş kapsamlı alan belirlenir,
- Rüzgar türbinlerinin sayılarını ve kapasitelerini göz önüne alarak ve çapraz korelasyon analizi yaparak kapsama alanındaki diğer sahalar belirlenir,
- Yapıyı oluşturan tasarım faktörleri belirlenir ve belirlenen faktörlerin seviyeleri belirlenir,
- Dört mevsim için veri seti kullanarak ESA çalıştırılır,
- Her deney için sinyal-görüntü oranını değerlendirilir,
- Faktör düzeylerinin ortalama etkileri hesaplanır,
- Yapılan hesaplama göre en uygun sağlam tasarım bulunur,
- Sağlam tasarımla optimum ESA çalıştırılır, optimal sinyal-görüntü oranı orijinal deneydeki herhangi bir sinyal-görüntü oranından daha küçükse yapıyı oluşturan tasarım faktörleri yeniden belirlenir, aksi durumda deney sonlandırılır.

Şeklindedir. Çalışmanın sonucunda deneme yanılma yerine Taguchi ortogonal deneyler kullanılarak yüksek tahmin doğruluğu korunurken iki boyutlu ESA geliştirme süresi büyük ölçüde azaltılabileceğine değinilmiştir [13].

Siamak Mehrkanon, hava durumu verilerinde sıcaklık ve rüzgâr hızı tahmini için ESA mimarisine dayanan tahmin modelleri üzerinde çalışmıştır. Çalışmada kullanılan modeller uçtan uca aynı anda birden fazla kullanıcı tanımlı hava istasyonu için tarihsel verileri ve hava tahmin unsurlarını kullanarak, çok değişkenli hava durumu verilerinden yararlanılmıştır. Çalışmada önerilen modellerden ilki, bir boyutlu evrişimli katmanları

kullanarak bireysel hava istasyonlarının geçmiş verilerinden yeni temsilleri öğrenmek ve ardından bunları çıkış katmanlarından önce birleştirmektir. Bu mimari, çok kaynaklı evrişimli NARX modeli olarak kabul edilebilir. Bu yaklaşım, yalnızca tüm mevcut meteoroloji istasyonlarından alınan geçmiş verileri eş zamanlı olarak dikkate alarak keşfedilebilecek öğrenme özelliklerini göz ardı edebilir. Bu nedenle, ikinci ve üçüncü modeller, aynı anda birden çok hava istasyonundan geçmiş hava durumu öğelerini araştırır ve yeni tahmini paylaşılan temsilleri öğrenir. İkinci ve üçüncü modellerde, birinci modelden farklı olarak girdiler, hava durumu verilerinin uzay-zamansal yapısını korumakta ve bu nedenle, verilerin temel yapısı dikkate alınarak yeni özellikler ortaklaşa öğrenilmektedir. Çalışmada sıcaklık tahmini ve rüzgâr hızı tahmini için iki ayrı deney seti kullanılmıştır. İlk deneyde sıcaklık tahmini için, Brüksel, Liege, Antwerp, Amsterdam, Eindhoven ve Groningen'de bulunan altı meteoroloji istasyonundan alınan ölçümler kullanılmıştır. Deneylerde, hava durumu değişkenlerinden dolayı boyut azaltmak için evrişimli katmanları kullanılmıştır. Ayrıca, önerilen modellerin performansını NARX modeli ve uzun kısa süreli bellek ağları ile karşılaştırılmıştır. İkinci deneyde ise rüzgâr hız tahmini için Danimarka'da bulunan Esbjerg, Odense, Roskilde olmak üzere üç meteoroloji istasyonu için 6 ve 12 saat ilerideki rüzgâr hızı tahminiyle ilgili olarak, 2000–2010 yılları arasında sıcaklık, basınç, rüzgâr hızı ve rüzgâr yönü dâhil olmak üzere dört hava unsurunu içeren saatlik tarihsel veriler kullanılmıştır. Çalışmanın sonucunda, Ağ konfigürasyonunda farklı evrişimli katman türlerini birleştirmenin, önerilen ağların boyutsallık azaltma yetenekleri, temsili öğrenme sayesinde tahmin performansını nasıl artırabileceğini gösterilmiştir. Özellikle iki boyutlu ve 3 boyutlu ESA'lar, incelenen görevler üzerinde umut verici olduğu gösterilmiştir [14].

Zherui Maa ve diğerleri, rüzgâr hızının doğası gereği, rüzgâr hızlarını doğru bir şekilde tahmin edebilmek için çift ayrıştırma, hata düzeltme stratejisi ve derin öğrenme algoritmasına dayalı yeni bir kısa vadeli rüzgâr hız tahmin modeli önermişlerdir. Çift ayrıştırma stratejisi ile orijinal rüzgâr hızı serileri ve hata serileri, her serinin karmaşıklığı azaltmak için sırasıyla ayrıştırılmıştır. Uzun kısa süreli bellek sinir ağı ile alt seriler için tahminin tamamlanması önerilmiştir. Uyarlanabilir gürültü ile deneysel mod ayrışımı, değişken mod ayrışımı ve uzun kısa süreli bellek sinir ağı birleştirilerek yeni bir rüzgâr hız tahmin modeli oluşturulmuştur. Oluşturulan bu modelle daha derin özelliklerin çıkarılması ve modelin düzeltme etkisini iyileştirmek amaçlanmıştır. Önerilen modellerin doğruluğunu

ve geçerliliğini doğrulamak için dokuz model kullanılmıştır. Çalışma sonucunda hibrit modellerin tekli modellerden daha yüksek tahmin doğruluğuna sahip olduğu söylenmiştir. Yani, uyarlanabilir gürültü ile deneysel mod ayrışımı ile uzun kısa süreli bellek sinir ağı birleşimi ve topluluk deneysel mod ayrışımı ile uzun kısa süreli bellek sinir ağı birleşiminin, tek başına kullanılan uzun kısa süreli sinir ağı birleşimine göre daha üstün olduğu söylenmiştir. Yine çalışmada kullanılan çift ayrıştırma stratejisinin tek ayrıştırma stratejisinden üstün olduğu belirtilmiştir. Önerilen modelin kısa vadede avantajları olmasına rağmen rüzgâr hızı tahmini, nem, basınç ve sıcaklık gibi faktörlerin etkisinde olduğundan, gelecekteki çalışmalar, bu etkileyen faktörleri dikkate almalı ve bunları rüzgâr hızı tahminine dâhil etmelidir [15].

V. Chandran ve diğerleri, rüzgâr enerjisi üretimini tahmin etmek için makine öğrenimi algoritmalarını kullanarak rüzgâr gücü değerlerinin etkin bir şekilde tahmin edebilecek bir sistem önermişlerdir. Bu makine algoritmaları, uzun kısa süreli bellek, geçitli referans birimi ve tekrarlayan sinir ağlarıdır. Çalışmada veri olarak Brüksel, Belçika'da deniz seviyesinden 109 metre yükseklikte bulunan 2.3 MW, üç kanatlı rüzgâr türbini kayıtları kullanılmıştır. Rüzgâr türbininden, tarih, saat, ortam sıcaklığı, rüzgârın akış yönü, rüzgârın hızı ve rüzgâr tribününden üretilen rüzgâr enerjisi verileri olmak üzere toplamda 50.530 adet veri kullanılmıştır. Önerilen modeller, NVIDIA Quadro RTX 6000 ile Intel İ9 işlemcide uygulanmış ve test edilmiştir. İncelediğimiz makalenin yazarları, doğru tahmin modellerine duyulan ihtiyaç nedeniyle sayısal hava tahmini girdilerini kullanmadan istatistiksel model uygulaması teşvik etmişlerdir. Rüzgâr hızı tahmini, gerçek zamanlı seri veri koleksiyonundan, karmaşık verileri ve doğrusal olmayan özellikleri çıkarmak için tasarlanmış geçitli referans birim ağı aracılığıyla daha da geliştirilmiştir. Zor işletme problemlerini tahmin etmek, riski en aza indirmek ve verimliliği artırmak için modern elektrik güç sistemleri rüzgâr enerjisi tahminleri kullanılmıştır. Çalışma sonucunda geçitli referans birim ağının rüzgâr hızı tahminini daha da arttırmak için girdi veri setinden, doğrusal olmayan ve karmaşık verileri gerçek zamanlı olarak çıkarmak için daha uygun olacağı bulunmuştur [16].

Ying-Yi Hong ve diğerleri, 24 saat ilerideki rüzgâr enerjisi üretim tahmini için hibrit bir derin öğrenme sinir ağı sunmaktadır. Çalışma, çift gauss fonksiyonuna sahip bir radyal tabanlı fonksiyonel sinirsel ağ ile basamaklandırılmış bir ESA'ya dayanmaktadır. Bu

yöntem ile ESA'daki katman sayısı, sınırlı bilgi nedeniyle geleneksel çoklu gizli katmanların ve özellik çıkarıcıların dezavantajlarının üstesinden gelerek, evrişim, çekirdek ve havuzlama işlemleriyle rüzgâr gücü özelliklerini çıkarmak için kullanılır. Hem aralıklı rüzgâr özelliklerinin hem de özellik çıkarımlarından kaynaklanan veri artışlarının neden olduğu belirsizlik, çift gauss fonksiyonu ile modellenebilmektedir. Önerilen radyal tabanlı fonksiyonel sinirsel ağ, tüm nöronlar arasında bağlantılara sahiptir. Radyal tabanlı fonksiyonel sinirsel ağındaki çıkış nöronlarının sayısı, derin öğrenme kullanılarak bir gün öncesi tahmininde yaygın olarak kullanılan 24 olacak şekilde tasarlanmıştır. 24 sayısı belirlendikten sonra, bu çıktıları üretmek için yeterli ESA girdisi gerekir ve buda 24'ün katı olan 48 olarak bulunmuştur. Bulunan 48 yuvarlanarak 50 olarak kabul edilmiştir. Çalışmada yanlışları önlemek için 0,5 oranında bırakma oranı kullanılmış ve böylece radyal tabanlı fonksiyonel sinirsel ağ için giriş sayısı 40 olarak bulunmuştur. Önerilen yöntemin performansını doğrulamak için kış aylarının genellikle Aralık ayı gibi başladığı, Tayvan, Changhua ilçesindeki Changgong rüzgâr çiftliğinden elde edilen Aralık 2014 – Kasım 2015 tarihleri arasında açık deniz türbinlerindin bir tanesinin verileri kullanılmıştır. Çalışmanın sonucunda, diğer yöntemlerden daha iyi performans sergilendiğinden bahsedilmiştir. Gelecekteki çalışmalar, daha iyi gün öncesi tahminleri elde etmek için farklı hava istasyonlarından alınan uzay-zamansal veri kümelerini kullanacak ve aykırı değerlerin olumsuz etkisini ve tahmin performansı üzerindeki sahte verilerin varlığını ortadan kaldıracabilecek bir veri ön işleme algoritması geliştirecektir [17].

Min Zhou ve diğerleri, alt ve üst sınır tahmin yöntemleriyle tahmin aralıkları oluşturmak için uzun kısa süreli bellek sinir ağlarına dayalı bir tahmin modeli, tahmin aralıklarının tahmin hataları dikkate alınarak geliştirilmiş bir değerlendirme kriteri ve tahmin hatası ile ortalama genişlik arasındaki ilişkiyi araştırmak amacıyla çok fonksiyonlu bir optimizasyon çerçevesi önermişlerdir. Önerilen uzun kısa süreli bellek sinir ağı tabanlı aralıklı tahmin modeli gerçek dünyadaki rüzgâr enerjisi veri setleriyle test edilmiştir. Karmaşık problemleri çözmek için baskın olmayan hızlı sıralama genetik algoritması kullanılmıştır. Bu algoritma öğrenme mekanizması ile birlikte daha da geliştirilmiştir. Çalışmada önerilen tahmin aralıkları değerlendirme indeksi ile nokta tahmin yöntemlerinden farklı olarak tahmin aralıklarındaki belirsizliklerin ölçülmesi amaçlanmıştır. Aralıklı tahmin yöntemleri, önce gelecekteki rüzgâr enerjisi için bir nokta tahmini elde etmek için bir regresyon modeli uygulayıp, sonrasında ise belirli bir veri dağılımına dayalı olarak alt ve

üst sınırlar elde etmektedir. Çalışmada alt ve üst sınır tahmin yöntemini gerçekleştirmek için aşırı öğrenme makinası, çok katmanlı algılayıcılar ve radyal tabanlı fonksiyon sinir ağı gibi makine öğrenimi modelleri başarıyla kullanılmıştır. Çalışma sonucunda rüzgâr üretimi belirli bir zamansal sıralamaya sahip olduğundan uzun kısa süreli bellek sinir ağı uygun bir tahmin modeli olabildiği, ancak veri seti zaman serisi özelliklerini göstermediğinde, önerilen modelin kaliteli tahmin aralıkları elde edilemeyeceği sonucuna varılmıştır. Bu nedenle, önerilen yöntem zaman serisi tahmin görevlerini işlemekle sınırlı tutulmuştur. Gelecekteki çalışmalarında, zaman serisi olmayan modellerin rüzgâr gücü aralığı tahmininde nasıl kullanılacağına araştırılacağı, rüzgâr enerjisinin aralıklı tahmini için en uygun veri bölme yolunu bulmak için farklı veri bölme yöntemlerinin araştırılacağı bildirilmiştir [18].

Xiasheng Peng ve diğerleri, sayısal hava tahmini girdilerini ve derin öğrenme yöntemlerini dikkate alarak rüzgâr enerjisi tahmini için EALSTM-QR adında yeni bir sinir ağı tahmin modeli geliştirmişlerdir. Geliştirilen bu model; kodlayıcı, dikkat seviyeleri, uzun kısa süreli bellek ve niceliksel regresyon olmak üzere dört ana düzeyden oluşmaktadır. Çalışmada, sayısal hava tahmin verileri tarafından yönlendirilen rüzgâr gücü tahmin modeli geliştirmek amaçlanmaktadır. Önerilen bu modelde ağ, kodlayıcı özellik çıkarımından elde edilen yüksek boyutlu sayısal hava tahmin veri setini kabul eder ve dikkat süreci ve ağ eğitiminden sonra aralık tahmin sonuçlarını elde eder. Çift yönlü uzun kısa süreli bellek, zaman serisindeki tüm bilgileri göz önünde bulundurularak doğru bir tahminde bulunulabileceğinden eğitim ağı olarak alınmıştır. Son olarak, aralıklı tahmin sonuçları, niceliksel regresyon yöntemi aracılığıyla olasılık tahmin sonuçları oluşturmak için kullanılmıştır. Çalışmada veri kaynağı olarak 1 Ocak 2017 – 31 Aralık 2018 tarihleri arasında Çin'in Ningxia şehrindeki dört rüzgâr çiftliği kullanılmıştır. Çalışmada kullanılan veri setleri, bir yıl boyunca yerel bir rüzgâr çiftliğinin rüzgâr gücüne ilişkin bilgileri içermektedir. Rüzgâr enerjisi her 15 dakikada bir kaydedilerek, tek bir veri setinden oluşan toplam 63168 veri kullanılmıştır. Deneylerde, her bir veri seti için verilerin ilk %80'i eğitim için, son %20'si ise test için kullanılmış, her veri kümesi için, sonuçlardaki belirsizliği önlemek için her modelin sonuçlarının 10 deney üzerinden ortalaması alınmıştır. Deney sonuçları ve yapılan analizler sonucunda, rüzgâr gücü verilerini ve sayısal hava tahminini birleştiren modelin, çok boyutlu metrikler açısından karşılaştırma modellerinden daha iyi performans göstermiştir. İlerideki çalışmalarda rüzgâr enerjisi

tahmin doğruluğunu artırmak için, makine öğrenimi algoritmalarını kullanarak sayısal hava tahmini ham verilerinin modele daha eksiksiz şekilde nasıl uygulanacağı üzerinde çalışmalıdır [19].




3. RÜZGÂR ENERJİSİ

Tezimizin bu bölümünde; enerji, yenilenebilir enerji kaynaklarının en çok tercih edilen türlerinden biri olan rüzgâr enerjisi ve rüzgâr enerjisinin Türkiye’de ve Dünya üzerindeki potansiyelinden bahsedilecektir.

3.1. Enerji

Hayatımızın her alanında bulunan enerji vardan yok, yoktan var edilemez. Başka bir tabirle enerji kavramı iş yapabilme yeteneği olarak tanımlanmaktadır. Enerji, başka enerji türlerine dönüştürüle bilindiği gibi her zaman başka enerji türlerine dönüştürülemezler. Enerjinin başka bir enerjiye dönüştürülmesi olayına kullanılabilir enerji diğer bir adıyla ekserji, dönüştürülememesi olayına ise kullanılmayan diğer bir adıyla anerji denilmektedir. Enerji kaynakları ve gruplandırılmaları Şekil 3.1’de gösterilmiştir.




Şekil 3.1. Enerji kaynakları ve gruplandırılmaları

Enerji, yaşamın devamı için kritik bir öneme sahiptir çünkü birçok endüstriyel alanda, ulaşım, ısınma, aydınlatma ve daha birçok günlük yaşantılarımız enerjiye bağlıdır. Gelişen ülkeler, ekonomik büyüme ve kalkınma için büyük ölçüde enerjiye ihtiyaç duymaktadır. Sanayi, ulaşım, tarım, hizmet sektörlerindeki artan talepler ve Dünya nüfusunun hızla artıyor olması da enerjiye olan ihtiyacı arttırmaktadır. Enerjinin çevreye olan endişeleri araştırıldığında fosil yakıtlardan kaynaklanan sera gazı emisyonları ve iklim değişikliği gibi çevresel sorunlar enerji kaynaklarına yönelik oluşan talepleri olumsuz etkilemektedir. Enerji, günümüzdeki yaşam tarzımızın ve ekonomik faaliyetlerimizin anahtar bir unsuru haline gelmiştir. Sürdürülebilir enerji kaynaklarına yatırım yapmak ve enerji verimliliğini arttırmak, gelecek nesiller için yaşanabilir bir dünya sağlamak için önemli adımlardır [20].

3.1.1. Rüzgâr Enerjisi


Rüzgâr enerjisi yenilenebilir enerjinin önemli türlerinden biri olarak kabul edilebilir ve yeni endüstrilerin gelişmesi ile birlikte rüzgâr enerjisi üretim teknolojilerinde hızlı bir küresel büyüme oluşturulmuştur. Rüzgâr enerjisi aynı zamanda tüm YEK'lerin arasında en hızlı ve en çok gelişen enerji kaynağıdır [21].

Rüzgâr Enerjisi üretmek için kurulan rüzgâr türbinleri yerleşim yerlerine uzak olmaları nedeniyle şebekeye bağlanmasında bağlantı problemi oluşturmaktadır. İlk yatırım maliyetlerinin yüksek olması, üretilen enerjinin stoklanması ve çevresindeki 2-3 kilometrelik alanda TV sinyallerinin bozulması gibi dezavantajlarının yanı sıra; enerji üretirken doğaya sera gazı veya bunun gibi zararlı gazlar salınmazlar, diğer enerji kaynaklarına göre daha az yer kaplamaları, karalık ve aydınlık ortamların önemsiz olması nedeniyle gece gündüz elektrik üretmesi, bakım ve işletme maliyetinin düşük olması gibi avantajları bulunmaktadır.



Şekil 3.2. Üç kanatlı yatay eksenli bir rüzgâr türbinin şeması [22]

Enerji üretimi için birçok farklı türde rüzgâr türbinleri test edilmiş, çoğunlukla Şekil 3.2’de gösterildiği gibi yüksek bir kulenin tepesine monte edilmiş, bir şaftın bir ucunda bir rotor ve diğer ucunda bir jeneratör bulunan yatay eksenli rüzgâr türbinleri kullanılmaktadır. Şekil 3.3’de ise yatay eksenli bir rüzgâr türbinin gövdesindeki aktarma organlarının şeması gösterilmiştir.



Şekil 3.3. Yatay eksenli bir rüzgâr türbinin gövdesindeki aktarma organlarının şeması [22]

Günümüzde kullanılan rüzgâr santrallerinin çoğu kara üzerine kurulmaktadır. Bununla birlikte kıyı sularında ve açık denizlerde de rüzgâr santralleri inşa edilmektedir. Açık denizlerde santralleri inşa etmek, türbin için bir deniz tabanı oluşturmayı gerektirdiğinden karada rüzgâr türbinlerini kurmaktan daha zordur. Bununla birlikte açık denizlerde kurulan rüzgâr santrallerine çevresindekilerin itirazlarının daha az olması nedeniyle inşaat izni almak daha kolaydır. Açık denizlerdeki rüzgâr rejimi genellikle karadakinden daha iyidir, bu nedenle açık denizlerde kurulan bir rüzgâr santralinin, karada kurulan aynı kapasitedeki bir tesisten daha fazla elektrik üretebilir [22].

Rüzgâr enerjisinin tarihçesine bakılacak olursa; Rüzgâr enerjisinden en eski yararlanma türleri yel değirmenleri ve yelkenli gemilerdir. Yelkenli gemilerde rüzgârın kinetik enerjisi gemileri hareket ettirmek için kullanılmış, yel değirmenlerinde ise buğday gibi tahılların öğütülmesinde kullanılmıştır. İnsanlar yelkenli gemileri hareket ettirmek ve gemileri yürütmek için 5500 yıldan beri rüzgârın gücünden faydalandığı bilinmektedir. Yel değirmeninin ortaya çıkması ise çok daha sonra olmuştur. İlk kez Yunan mühendis Heron'un milattan sonra 1. yüzyılın başlarında rüzgâr enerjisinin kullanımı tanımlamış ve tarif etmiştir, daha sonra bu sistem İran'da geliştirilerek yel değirmenleri ortaya çıkmıştır [23].

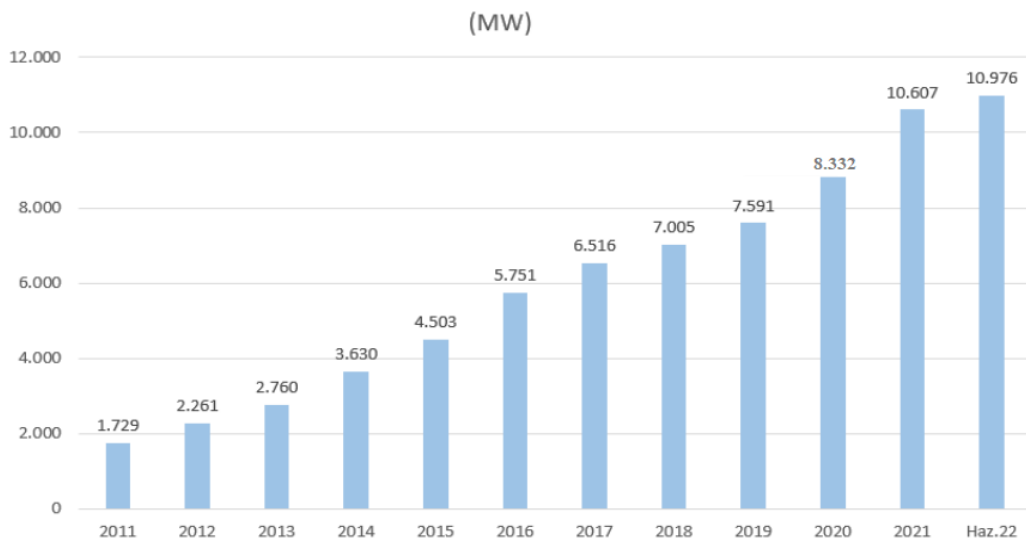
İnsanlar, milattan önceki zamanlarda, yelkenli gemilerin yözdürülmesi, alçak seviyelerdeki suların yükseğe çıkarılmasında ve buğdayların öğütülmesinde rüzgâr enerjisinden yararlanmıştır. Haçlı seferleri ile İran'da bulunan yel değirmenleri Batı'ya alınmıştır. Rüzgâr enerjisi daha çok Asya uygarlıklarından olan Çin, Tibet, Hindistan, İran ve Afganistan'da kullanılmıştır. Milattan önce 300 yıllarında rüzgâr türbinleri ile ilgili yazılı bilgiler ortaya çıkmıştır. Bu yazılarda yatay eksenli yel değirme ile ilgili bilgilere yer verildiği ve İranlıların da düşey eksenli yel değirmenlerini kullandıkları bilinmektedir. 10. Yüzyıl yakınlarında rüzgâr gücünün Asya kıtalarından Avrupa kıtalarına geçtiği bilinmektedir [24].

Rüzgâr türbini olarak adlandırılan ve enerji üretiminde kullanılan ilk makinalar, 1980 yılının ilk çeyreğinde Danimarka'da yapılmıştır. Rüzgâr enerjisinden elektrik üreten ilk türbin ise 1891 yılında Paul la Cour tarafından Danimarka'da inşa edilmiştir. Rüzgâr türbinleri ilk zamanlarda Profesör Ulrich Huger tarafından iki kanatlı bir şekilde fiberglas


ve plastik maddelerden yapılmış, 1980'li yıllarda ise türbinlerdeki kanat sayıları üçe yükseltilerek düşey eksenli ve yatay eksenli türbinlerin çeşitli modelleri üretilmiştir [25]. Türkiye'de ilk kez rüzgâr enerjisinden elektrik üretimi, 55 kilowatt (KW) elektrik üretme kapasitesiyle İzmir'in Çeşme İlçesinde Altın Yunus Tesislerinde 1986 yılında gerçekleşmiştir. Yine 1998 yılında İzmir ili Çeşme ilçesi Germiyan köyünde kurulan rüzgâr türbininden uluslararası alanda kabul görmüş ilk üretim gerçekleştirilmiştir.

3.1.2. Türkiye ve Dünyada Rüzgâr Enerjisinin Mevcut Durum Analizi

Türkiye'de sanayileşme son yıllarda gelişmiş ülkelere göre gelişme göstermektedir. Aynı zamanda gelişmişliğin bir ölçüsü olan kişi başına düşen enerji tüketiminin artması enerjinin önemini ortaya koymaktadır. Türkiye'nin birincil enerji talebi yılda %4-5 oranında artmakta ve elektrik enerjisi talebindeki artış oranı %8'dir. Türkiye'de yerli enerji kaynakları oldukça az kullanılan kaynaklardır. Türkiye'nin temiz yenilenebilir enerji teknolojilerine ilgi ve desteğini göstermesi gerekmektedir. Bu itibarla çevreyi kirletmeyen ve diğer kaynaklara göre daha verimli bir yapıya sahip olan rüzgâr enerjisi üzerinde çalışmaların sürdürülmesi gerekmektedir [26]. Türkiye'nin rüzgâr enerji potansiyeli 48.000 Megawatt (MW) olmasına rağmen 2022 yılı haziran ayı sonuna kadar kurulu rüzgâr gücü 10.976 MW'tır (Şekil 3.4). Türkiye'de rüzgâr enerjisine dayalı gücün yıllara göre dağılımı Şekil 3.4'te toplam kurulu güç içerisindeki oran Şekil 3.5'te gösterilmiştir.




Şekil 3.4.Yıllara göre rüzgâr enerjisine dayalı kurulu güç [27]



Şekil 3.5. Türkiye’de toplam kurulu güç içerisindeki oran [27]


Rüzgâr potansiyeli bakımından zengin olan bölgelerimiz Ege, Marmara ve Doğu Akdeniz kıyılarıdır. Türkiye’de yer seviyesinden 50 metre yükseklikte ve 7,5 m/s üzeri rüzgâr hızlarına sahip alanlarda kilometrekare başına 5 MW gücünde rüzgâr santrali kurulabileceği kabul edilmiştir. Bu kabuller ışığında, orta ölçekli sayısal hava tahmin modeli ve mikro ölçekli rüzgâr akış modeli kullanılarak üretilen rüzgâr kaynak bilgilerinin verildiği Rüzgâr Enerjisi Potansiyel Atlası (REPA) hazırlanmıştır.

Türkiye’deki rüzgâr santrallerinin dağılımı Şekil 3.6’da gösterilmiştir. Buna göre haritada koyu renkle gösterilen yerlerde açık renkle gösterilen yerlere göre üretilen elektrik enerjisi daha fazladır. Gri renkle gösterilen yerlerde ön lisans çalışmaları yapılmış ancak henüz işletmeye alınmamış santraller gösterilmekte, siyah renk ile gösterilen yerlerde ise rüzgâr santrali kurulmadığı gösterilmektedir. Sadece işletmeye alınan rüzgâr santralleri dikkate alındığında ülkemizde 1.749 MW kurulu gücü ile en yüksek elektrik üretimine İzmir ili sahiptir [28].



Şekil 3.6. Türkiye'deki Rüzgâr Santrallerinin Dağılımı [28]

Dünya, enerji ihtiyacının büyük bir kısmını karşılamak için fosil yakıtları kullanmaktadır. Fosil yakıtların çevreye verdiği zararlar ve fosil kaynakların kullanım sürelerinin sınırlı olması dikkate alındığında YEK' in önemi ön plana çıkmaktadır. YEK' ler dünya genelinde önemli ölçüde araştırma konusu olmuş ve gelişimleri hızlıca artmaktadır. Teknolojik gelişmeler ve hızla artan enerji talebine karşılık rüzgâr enerjisine olan talepler de artmıştır. Rüzgâr enerjisi dünya çapında son on yılda aşağı yukarı dört katına çıktı ve maliyet açısından rekabetçi ve dayanıklı enerji kaynaklarından biri haline geldi. Bölgesel düzeyde 2020 yılı, Asya Pasifik, Kuzey Amerika ve Latin Amerika'daki rüzgâr enerjisi kurumları için de rekor bir yıl olmuştur. Bu üç bölge, geçen yıl toplamda 74 Gigawatt (GW) yeni kara rüzgâr kapasitesi ile artış sağladı. Afrika ve Orta Doğu'da, 2020 yılı kara rüzgâr enerjisi kurulu gücü 2019 yılındaki seviyeye yakın olarak 8,2 GW kapasitesine ulaştı. Şekil 3.7' de Dünya toplam rüzgâr kurulum kapasitelerinin tarihsel gelişimi gösterilmiştir. 2020 yılında dünya çapında açık deniz üzerinde toplam 6,1 GW kapasiteli rüzgâr enerjisi santralleri devreye alındı. Açık deniz rüzgâr enerjisinde Hollanda ilk sırada yer alırken, Belçika, İngiltere, Almanya ve Portekiz sırasıyla takip ederek Avrupa'da istikrarlı bir büyüme kaydedildi. Açık deniz rüzgâr enerjisi kapasitesi 2020 yılı sonu itibariyle 35 GW' ı geçti [29].



Şekil 3.7. Dünya toplam rüzgâr kuruluş kapasitelerinin tarihsel gelişimi [29]

3.2. Rüzgâr Hızı Tahmin Yöntemleri

Kesin olarak güvenli bir tahmin yöntemi bulunmamakla birlikte rüzgâr hızı tahmini için çok sayıda farklı yöntemler kullanılmaktadır. Rüzgâr hızı mevsimlere göre değişkenlik göstermektedir. Çok kısa sürelerde bile sağlıklı bir hız tahmini yapmanın mümkün olmadığı bu alanda araştırmacılar ve üretici firmalar birçok çalışma yapmışlardır. Rüzgâr hızı tahmin yöntemleri kullanılan metodolojiye ve zaman aralıklarına göre;

- Çok kısa süreli tahminler,
- Kısa süreli tahminler,
- Uzun süreli tahminler,
- Fiziksel yöntemler,
- Hibrit yöntemler,
- İstatiksel yöntemler,

şeklinde sınıflandırılmaktadır. Fiziksel yöntemler, zaman alıcı ve maliyetli olmasıyla birlikte sıcaklık, basınç, yoğunluk ve gibi fiziksel parametreleri dikkate alan uzun süreli ve rüzgâr hızı tahminlerinde kullanılan bir yöntemdir. İstatiksel yöntemler, kısa vadeli rüzgâr

hızı modelleme problemlerini ele almak için kullanılmaktadır. Ancak istatistiksel yöntemler doğrusal olmayan yapıları etkili bir şekilde inceleyemezler. Hibrit yöntemler verilerin iç özelliklerini tam olarak çıkaramayan ve gürültülü ortamları tam olarak temizleyemediğinden basit veri işleme yöntemlerine odaklanır. Bu yöntem tahmin sonuçlarının sürekliliğini ihmal eden tahmin doğruluğunu arttırmak için her zaman nesnel algoritma kullanmaktadır. Ayrıca yakın zamanda öğrenme yaklaşımları ve yapay zekâ uygulamaları da rüzgâr hızı tahminlerinde kullanılmaktadır. YZ yöntemleri uyum sorunlarına neden olabilir ve hassasiyet ve ölçeklenebilirlik açısından istenen tahmin sonuçlarını elde edemeyebilir [30].

3.2.1. Sayısal Hava Tahmini ve Rüzgâr Tahmini

Sayısal Hava Tahmini (SHT) ile rüzgâr hızı tahmin modeli geliştirilirken coğrafi alan, çözünürlük, doğruluk, hesaplama süresi ve çalıştırma sayısı gibi önemli kriterler dikkate alınmaktadır. SHT modeli adyabatik viskoz olmayan akışı temsil eden dinamik merkez, meteorolojik süreçlerin değişkenliğini tanımlayan fiziksel denklemler ve bilgi toplama yazılım kodu olmak üzere üç ana bileşene ayrılmaktadır. Bundan dolayı SHT modeli yalnızca rüzgârın değil, belirli zaman aralıklarında atmosferinde tahminidir. Bir ülkede veya ülkenin bir bölgesindeki rüzgâr gücünü tahmin etmek için bölgesel ve orta ölçekli seviyelerde SHT modelleri geliştirilmiştir. Rüzgâr enerjisi çıktısını tahmin etmek zaman alacağından yükseltme adı verilen bir yaklaşım kullanılmaktadır. Yükseltme tüm bölgenin ortalamasını aldığından tahmin hatasını azaltmaktadır. SHT' lerde matematiksel modellerin çok bulunması ve bunların birbiriyle ilişkili denklemler kullanılması dezavantaj olarak kabul edilmektedir [31].

3.2.2. İstatistiksel Hava Tahmin Modeli

İstatistiksel modeller bir takım tarihsel veriler yardımı ile problemi matematiksel modelini oluşturmak için parametre tahmini, örüntü tanımlama ve model kontrolünü kullanmaktadır. Kalman filtresi olarak bilinen filtrede bir istatistiksel yöntem olarak bilinmektedir. Kalman filtresi, SHT yöntemiyle elde edilen tahminler ile gözlemleri istatistiksel yöntemler ile değerlendirir ve tahminler ile gözlemler arasında regresyon kurar. Diğer bir istatistiksel yöntem ise geleneksel bir yöntem ile karşılaştırıldığında tahmin doğruluğunu iyileştirmeye

yardımcı olan zamansal korelasyonlara dayanan uzamsal korelasyondur. Yapılan literatür taramasına göre İstatiksel Hava Tahmin Modeli olarak otoregresif model (AR), hareketli ortamlar modeli (MA), otoregresif hareketli ortamlar modeli (ARMA) ve otoregresif entegre hareketli ortamlar modeli (ARIMA) modellerinin kullanıldığı görülmektedir. ARMA modeli ortalama saatlik rüzgâr hızını tahmin etmek için kullanılmış ve kalıcılık modeliyle karşılaştırılmıştır. Yapılan bu karşılaştırmada 1 saatlik tahmin sürecinde kalıcılık modelinin ARMA modelinden daha az hataya sahip olduğu, tahmin süresi 10 katına çıkarıldığında ARMA modelinin daha az hata verdiği gözlemlenmiştir. Kısa süreli tahminler ve düşük tahmin hatalarına karşılık, rüzgar serilerinin saatlik tahmini için klasik Box Jenkins yöntem bilimine dayanan otoregresif entegre hareketli ortamlar modeli olarak bilinen ARIMA modeli geliştirilmiştir. Sinir Ağları, Destek Vektör Makinaları, Bulanık Mantık ve Regresyon ağaçları istatistiksel yöntemlerin alt dallarını oluşturmaktadır [32].

3.2.2.1. Yapay Sinir Ağları İle Rüzgâr Hız Tahmini

Rüzgâr hızı tahmininde daha doğru ve güvenilir tahminler elde etmek için, fiziksel model, geleneksel istatistiksel model ve yapay zekâ modeli olarak ayrılabilen birçok model geliştirilmiştir. YZ'nin gelişmesiyle birlikte YZ modelleri, zaman serileri tahmini alanında büyük başarılar elde etmiştir. YZ'ya dayalı rüzgâr hızı tahmin modelleri, araştırmacılar tarafından büyük ölçüde benimsenmektedir. YZ'nin en klasik algoritması yapay sinir ağlarıdır. YSA modelinin popüler bir yapısı olan derin öğrenme, son yıllarda zaman serisi tahminlerinde yaygın olarak kullanılmaya başlanmıştır. Literatür taramasına göre, gözden geçirilmiş bazı rüzgâr hızı tahmin modelleri Tablo 3.1'de özetlenmiştir [33].

Rüzgâr hızı tahmin modelleri, rüzgâr karakterizasyonu, kaynak tahmini ve tahmin için dünya çapında rüzgâr enerjisi üretiminin hızla yayılmasını sağlamaktadır. Araştırmacılar rüzgâr verilerinin mevcut olmaması nedeniyle yıllarca farklı tahmin modelleri kullanmışlardır. Literatürde araştırmacılar YSA ile rüzgâr hız tahmini modelinde girdi olarak bağıl nem, ortalama rüzgâr hızı, rüzgâr yönü gibi parametreler kullanmakta ve çıkış parametreleri olarak ise rüzgârdan elde edilen enerji kullanılmaktadır. Yine rüzgâr hızı ve rüzgâr gücünü tahmin etmek için YSA modelini kullanan Çam, girdi değişkeni olarak boylam, enlem, yükseklik, yükseklik çıktı olarak ise rüzgâr hızı ve rüzgâr gücünü kullanmıştır. Bechrakis, YSA kullanarak farklı bölgelerin yıllık rüzgâr hızını tahmin etmek

için bir yerin bir yıllık ölçülen rüzgâr hızını kullanmış ve YSA eğitimi için kullanılan bir ve iki aylık rüzgâr hızı verilerinin tatmin edici sonuçlar verdiği bulmuştur [34].

Tablo 3.1. İncelenen bazı rüzgâr hızı tahmin modelleri

Yayın Yılı	Model
2018	ICEEMDAN-GWO-BP-ENN-WNN-GRNN
2019	SSA-EMD-CNNSVM
2019	WD-SE-VMD-MadaBoost-BFGS-WF
2019	WPD-Boost-ENN-WPF
2020	EWT-DCPELM-IEWT(Spark)
2020	VMD-FOA-DBN-ARIMA

3.2.2.2. Destek Vektör Makinesi İle Rüzgâr Hız Tahmini

Destek Vektör Makinesi (DVM), yapısal risk ilkesini benimseyen ve mükemmel genelleme yeteneğine sahiptir. Doğrusal olmayan yaklaşım kapasiteleri ve uyarlanabilir öğrenme ele alındığında DVM'nin küçük örneklemeleri ve doğrusal olmayan verileri işlemede büyük avantaja sahiptir. DVM modeli küçük numune verilerinin işlenmesinde çok iyi öğrenme kabiliyeti olması nedeniyle kısa vadeli rüzgâr enerjisinin tahmini için uygundur. Bundan ötürü çalışmalarda genellikle rüzgâr enerjisi tahmini için temel model olarak seçilmektedir. DVM'nin tahmin performansı üzerinde parametre seçiminin etkisi büyüktür. Kılavuz arama gibi geleneksel yöntemler en iyi performansı seçmek için genellikle farklı parametre kombinasyonlarını karşılaştırmaktadır. Bu tür yöntemler hassas ve büyük ölçekli hesaplama yapamayan numaralandırma yöntemine aittir. Bunun önüne geçmek içinde farklı algoritmalar önerilmektedir [35].

Rüzgâr enerjisi kaynaklarının doğru ve hızlı olarak tahmin edilebilmesi için geçmişten günümüze kadar DVM'ler sıklıkla kullanılmakta ve uygulanmaktadır. Rüzgâr enerjisi kaynaklarının tahmininde dünya çapında araştırmacıların DVM'lere olan ilgisi her geçen gün artmaktadır. Yapılan çalışmalara bakacak olursak; Mohandes, Suudi Arabistan'ın Medine şehri için 1970-1982 yılları arasında 12 yıllık veri seti kullanarak geliştirmiş oldukları DVM ile güvenilir ve tatmin edici bir hassasiyetle çok katmanlı algılayıcılar ile

kıyaslama yapılmış ve DVM modelinin ortalama karesel hata değerinin çok katmanlı algılayıcılardan düşük olduğu kanıtlanmıştır. Zho, Kuzey Dakota' da 2002 yılının saatlik rüzgâr hızı verileri ile DVM'lerin en küçük kareler modelini kullanarak kısa vadeli rüzgâr hızı tahmininde bulunmuşlardır. Yapılan çalışmada veri seti dört mevsimsel veri setine bölünmüş ve lineer, radyal tabanlı fonksiyon ve çoklu çekirdekli fonksiyon parametreleri kullanılmıştır. Modellerin etkinliği karekök ortalama hata aracılığıyla değerlendirilmiş ve kalıcılık modeliyle karşılaştırıldığında DVM'lerin en küçük kareler modelinin sağlamlığı kanıtlanmıştır. Bunun yanı sıra Tagliaferri ve arkadaşları DVM ile rüzgâr yönü tahmini üzerinde çalışmalar yapmıştır. Bu çalışmayı yapan araştırmacılar veri olarak San Francisco'daki 34. Amerika Cup sırasında toplanan kayıtları kullanmışlardır. Giriş çıkış parametreleri olarak da sırasıyla son dakikalardaki rüzgâr yönü ölçümleri ve sonraki 2 dakikadaki rüzgâr yönü kullanılmıştır. YSA ve destek vektör regresyon yöntemlerinin performanslarını test etmek için son 100 dakikayı ve her iki modeli eğitmek için kullanılmayan diğer veriler kullanılmıştır. Sonuç olarak destek vektör regresyonunun doğruluk ve hesaplama süresi açısından iyi bir yeteneğe sahip olduğu kanıtlanmıştır [36].

3.2.2.3. Bulanık Mantık Yöntemi İle Rüzgâr Hız Tahmini

Bulanık mantık yöntemi, insan duygularının algılanmasına ve yorumlama süreçlerine benzetilmektedir. Bulanık mantık kontrol sistemi aralıktan noktaya veya aralıktan menzile kontrol sistemi olarak bilinmekte ve bu yöntem titizliğin yanı sıra, tahmin edilen yöntemlerin güçlendirilmesini amaçlamaktadır. 1974 yılında Mamdani tarafından otomatik bir buhar makinesini kontrol etmek için pratik bir uygulama uygulanmış ve buna bağlı olarak yaklaşık on yıl sonra bulanık mantık teorisi tanınmıştır. Bulanık mantık yönteminin kullanımı, sınıflandırmanın belirsiz, kesin olmayan nitel ifadesi ile uygundur. Bulanık kural kümeleri aynı özelliklere ait nesnelere sahiptir. Bir nesnenin belirli bulanık kural içerisindeki ayırt edici değeri 1 olarak kabul edilir, eğer değer bulanık kural dışında ise 0 olarak kabul edilmektedir. Bulanık mantık yöntemi, sayısal veriler biçiminde depolanan bilgiler ile başa çıkamamasına rağmen, bir dizi basit yöntemler kullanarak bir sistem davranışının daha iyi bir şekilde temsil edilmesini sağlamaktadır [37].

Bulanık mantık yöntemi belirli bir sistem davranışını bazı basit kurallar kullanarak daha iyi temsil edilmesini sağlar. Ancak sayısal veriler biçiminde depolanan bilgileri ele alamaz.

Mohandes ve arkadaşları, 1 Temmuz 2006 – 30 Kasım 2007 tarihleri arasında 17 ayık süre boyunca Suudi Arabistan'ın Juaymah şehrinde düşük yüksekliklerdeki ölçümlere dayalı olarak yüksek rakımlardaki rüzgâr hızının tahmin etmek için bulanık mantık yöntemi olan nöro-bulanık bir model kullanmıştır. Ölçümler yer seviyesinden 10,20,30 ve 40 m yükseklikte yapılmıştır. 40 m yükseklikteki rüzgâr hızını tahmin etmek için 10,20 ve 30 m yüksekliklerdeki 3 rüzgâr hızı değeri üzerinde eğitilmiştir. Eğitilen bu model 50 m yükseklikte tahmin yapmak için 20,30 ve 40 m yüksekliklerdeki rüzgâr hızı değerleri kullanılarak test edilmiştir. Bu süreç 100 m yüksekliğe kadar bu şekilde devam ettirilmiştir. Tahmin edilen değer ile ölçülen değer arasındaki ortalama mutlak yüzde hatası yaklaşık %3 olarak bulunmuştur [38].



4. MATERYAL VE YÖNTEM

Bu bölümde genel olarak yapay zekâ hakkında bilgiler verilecek ve yapay zekânın alt başlıklarına inilerek detaylandırılacaktır. Bunların dışında önerilen ağ modeli ve karşılaştırma yapılan diğer ağ modellerine değinilerek veri setimiz hakkında bilgilere yer verilecektir.

4.1. Yapay Zekâ

Yapay Zekâ, terimi ilk olarak 1956 yılında bilgisayar alanında çalışmalar yapmış John McCarthy tarafından tanıtılmıştır. YZ, makinalar tarafından insana özgü özelliklerin taklit edilmesi ve taklit edilen bu davranışların uygulamaya geçirilmesi işlemidir. Kelime anlamı olarak bir bilgisayarın kontrolü altında bulunan bir robotun canlılar gibi bazı faaliyetleri yerine getirme yeteneğidir. YZ, 1950'ler den berri matematik ve bilgisayar bilimi üzerinde çalışmalar yapılmıştır. İlk zamanlarda YZ, insanlar için entelektüel olarak zor ve zaman alıcı olan basit sorunları çözmeyi amaçlamıştır. Zamanla YZ, insanlar için gerçekleştirilmesi kolay olabilen ancak açıkça tanımlanması zor olan örüntü tanıma problemlerini çözmek için algoritmalar geliştirmeye odaklanmıştır.

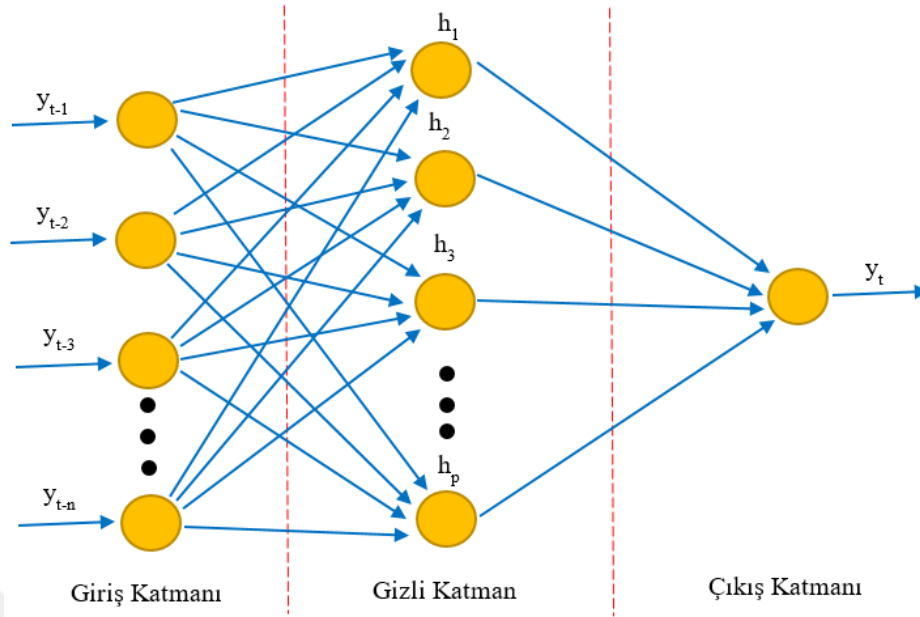
YZ'den bahsedilirken genel olarak kullanılan makine öğrenimi terimi, makinelerin öğrenme yeteneğini ifade eder. YZ, odaklandığı alanlardan biri olarak maine öğrenimini içerin bir üst kümedir. YZ'nin temelinde makinelerin çevreleri ve giriş parametreleri hakkındaki farkındalıklarına ve beklentilere dayalı olarak öngörülen görevleri yerine getirme yanıtlarına dayalı olarak ortaya çıkardığı şekilde bir zekâ geliştirmektir. Son zamanlarda YZ alanında derin öğrenme terimi de kullanılmaya başlanmıştır. Derin Öğrenme, makine öğreniminin bir alt kümesi olarak düşünülmektedir. Derin öğrenme, makine öğrenimini gerçekleştirmek için geliştirilen yapay zekânın bir sonraki adımudur. Derin öğrenme ile makine öğrenimi arasında bazı farklılık vardır. Makine öğreniminde özellikler algoritmalara manuel olarak girilirken, derin öğrenmede özellikler otomatik olarak oluşturulmaktadır. Özellikler, görüntüden çıkarılan bireysel ölçülebilir özellik veya karakteristik olarak tanımlanır. Özelliklerin manuel girilmesini gerektiren YZ

yaklaşımlarının yanı sıra derin öğrenme, doğru tahminler sunmak için daha büyük miktarda veri ve bilgi işlem gücü gerektiren daha karmaşık algoritmalar kullanır [39], [40].

4.1.1. Yapay Sinir Ağları

İnsan beyninin nörofiziksel özelliklerinden faydalanılarak bilim adamları tarafından matematiksel modeli çıkarılmaya çalışılmıştır. İnsan beyninin fiziksel bileşenlerinin tam olarak modellenmesi ve tüm davranışlarının modellenebilmesi ile harekete geçilerek çok sayıda yapay hücre ve ağ modelleri geliştirilerek, bilgisayarların algoritmik hesaplama yönteminden farklı olarak YSA'lar üzerinde durulmuştur [41].

YSA insanların beyinlerindeki bilgileri işleme tekniğinden ilham alınarak geliştirilmiş bir teknoloji olarak bilinmektedir. Yapay Sinir ağları; nöron, nöronlar arası bağlantılar ve öğrenme algoritması olmak üzere üç kısımdan oluşmakta olup yapay sinir ağlarının en temel parçası nörondur. Ağın içerisinde bulunan nöronlar probleme etki eden unsurlara göre birden fazla girdi alırlar ve bu alınan girdiler neticesinde problemde beklenen sonuç adedi kadar çıktı oluştururlar. Nöronların birbirleriyle bağlantı kurması ile yapay sinir ağı yapısı meydana gelmektedir. Nöronların aynı doğrultuda bir araya gelmeleri ile de katmanlar oluşmaktadır. Bir yapay sinir ağında girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katman bulunmaktadır. Şekil 4.1'de ileri beslemeli çok katmanlı bir yapay sinir ağı yapısı verilmiştir. Yapay sinir ağı katmanlarından olan girdi katmanı, ilk katman olmakla birlikte dışarıdan girilen verilerin ağırlıklandırılarak gizli katmana ulaştırması ile görevlidir. Son katman çıktı katmanı olarak bilinmektedir ve bilgilerin dış ortama aktarılmasını sağlamaktadır. Gizli katman olarak bilinen katmanda ise nöronların dış ortamla herhangi bir doğrudan bağlantısı bulunmamakta, yalnızca girdi katmanından gelen sinyalleri alarak, çıktı katmanına sinyal göndermekle görevlidirler [42].



Şekil 4.1. İleri beslemeli çok katmanlı bir yapay sinir ağı yapısı

Yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan YSA'lar veri tabanlı sistemler olarak bilinmekte olup insan beyninin öğrenme ve değişik koşullarda hızla karar verme gibi üstünlüklerin sadeleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesi amaçlanmaktadır. YSA'larda yapay nöronlar birbirleriyle ilişkilendirilmiş tabakalar halinde kümelenmektedir. YSA'ların hepsi genel olarak aynı yapıya sahiptirler. Bu yapıların dış mekân ile bağlantılı olabilmeleri için bazı nöronlar girdileri almak bazı nöronlar ise çıktılarını almakla görevlidirler. Geriye kalan tüm nöronlar ise gizli tabakadadırlar [41].

Uygulanan ağ modellerine göre yapay sinir ağlarının karakteristik özellikleri de değişmektedir. Birçok alanda üstünlük gösteren YSA'ların bu özellikleri YSA'ların problemleri çözebilme yeteneğini göstermektedir. YSA'ların özellikleri;

- Siteme uygun çözümler sağlamak için ağ tekrar tekrar eğitilebilmesi,
- Matematiksel modele ihtiyaç duymamaları,
- Bilginin saklanması,
- Eksik bilgi ile çalışabilmeleri,
- Öğrenme kabiliyetleri,

- Farklı öğrenme algoritmalarıyla öğrenile bilinmeleri,
- Görülmemiş örnekler hakkında bilgi üretebilmeleri,
- Örüntü ilişkilendirme ve sınıflandırma yapabilmeleri,

Şeklinde sıralanmakla birlikte bunun yanında;

- Probleme uygun ağ yapısını deneme yanılma yoluyla belirlenmesi,
- Yapay sinir ağlarının donanımlara bağımlı çalışmaları,
- Bazı ağlarda ağın parametre değerlerinin öğrenme katsayısı, katman sayılarının belirlenmesinde bir kuralın olmaması,
- Yapay sinir ağlarının yalnızca sayısal veriler ile çalışması,
- Farklı sistemlere uyarlanmasının zor olması,


gibi dezavantajları da bulunmaktadır [43].

YSA modelleri, tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli ve geri beslemeli yapay sinir ağları olmak üzere dört başlık altında incelenmektedir.

4.1.1.1. Tek Katmanlı Algılayıcılar

Sadece girdi ve çıktı katmanından oluşan tek katmanlı yapay sinir ağları, doğrusal problemlerin çözümünde kullanılmaktadır. Şekil 4.2’de Tek Katmanlı Algılayıcı (TKA) modeli gösterilmiştir. Bu tip ağlarda eşik girdisi yardımıyla nöron elemanlarının değerlerinin ve ağın çıktısının 0 (sıfır) olması önlenmektedir. Değeri her zaman 1’dir. Ağırlıklandırılmış girdi değerlerinin eşik değeri ile toplanması (4.1) sonucu ağın çıktısı bulunmaktadır.

$$\zeta = f \left(\sum_{i=1}^n w_i x_i + \varphi \right) \quad (4.1)$$



Şekil 4.2. Tek katmanlı algılayıcı

Denklem 3.4’de ağırlıklar $x_i, i=1, 2, \dots, n$ ile girdilere karşılık gelen ağırlık değerleri $w_i, i=1, 2, \dots, n$ ile ve eşik değeri φ ile gösterilmiştir. TKA’ da çıktı fonksiyonu doğrusaldır. Ağa gösterilenler eşik değer fonksiyonu (4.2) ile iki sınıf arasında paylaştırarak iki sınıfı birbirinden ayıran doğru (4.3) bulunmaya çalışılır. Ağırlık çıktısı 1 veya -1 değerini alır.

$$f(g) = \begin{cases} 1, & \zeta > 0 \\ -1, & \zeta \leq 0 \end{cases} \quad (4.2)$$

$$W_1X_1 + W_2X_2 + \varphi = 0 \quad (4.3)$$

Buradan;

$$X_1 = -\frac{W_2}{W_1}X_2 - \frac{\varphi}{W_1} \quad (4.4)$$

$$X_2 = -\frac{W_1}{W_2}X_1 - \frac{\varphi}{W_2} \quad (4.5)$$

olarak elde edilir.

TKA’larda Perceptron Modeli ve Adaline/Madeline Modeli olmak üzere iki model bulunmaktadır. Basit algılayıcılar olarak bilinen perceptron modeli bir sinir hücresinin birden fazla girdiyi alarak tek çıktı üretme ilkesine dayanır. Açık adı ADaptive LINEar Element olan Adaline modeli ise algılayıcılardan farklı değildir. Ancak algılayıcı aktivasyon fonksiyonu olarak eşik fonksiyonu kullanılırken ADALINE doğrusal fonksiyon kullanılmaktadır. İncelenen her iki modelde doğrusal olarak ayrılabilen problemlere çözüm üretebilmektedir [44].

4.1.1.2. Çok Katmanlı Algılayıcılar

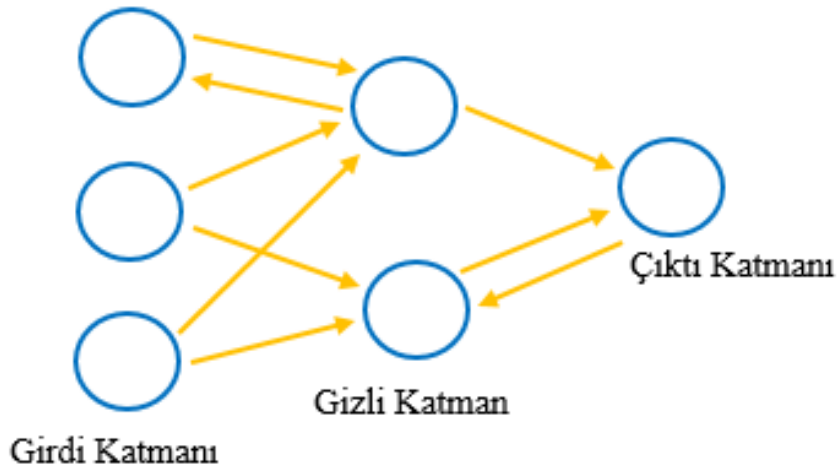
Doğrusal olmayan problemlerin çözümünde başarısız olan TKA’ların yerine geliştirilen çok katmanlı algılayıcılar (ÇKA), bilgi girişinin yapıldığı girdi katmanını, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşmaktadır. ÇKA’da, katmanlar arası geçişler, ileri yayılım ve geri yayılım sayesinde yapılmaktadır. İleri yayılım sürecinde hata değeri ve ağırlık

çıktısı hesaplanırken, geri yayılım sürecinde ise hesaplanan hata değerinin minimize edilmesi için katmanlar arası bağlantı ağırlık değerleri güncellenir. ÇKA’da katmanlar arası ileri ve geri yayılım olarak isimlendirilen geçişler bulunmaktadır. İleri yayılım sürecinde ağıın çıktısı ve hata değeri hesaplanır. Geri yayılım sırasında ise hesaplanan hata değerinin minimuma indirilmesi için katmanlar arası bağlantı değerleri güncellenir [44].

4.1.1.3. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli sinir ağları, ağı girdi görevi gören bağımsız değişkenler ile ağıın çıktıları olarak belirlenen bağımlı değişkenler arasındaki ilişkiyi öğrenmek için kullanılan matematiksel araçlar olarak kullanılır.

İleri beslemeli ağlar YSA’ların en kolay ve en temel yapısıdır. Bu ağıda bilgiler sadece gizli ve çıkış katmanına doğru ileri yönde hareket ederler. Sistem belleksizdir. İleri beslemeli ağı yapısına statik ağlarda denilmektedir. İleri beslemeli YSA’larda sinyaller daima ileri yöne taşınmaktadır. İleri beslemeli bağlantıların ağırlıkları eğitim sırasında değiştirilebilir ama geri dönüşümlerin bağlantı ağırlıkları sabittirler ve değiştirilemezler. Şekil 4.3’de ileri beslemeli YSA yapısı gösterilmiştir [45].

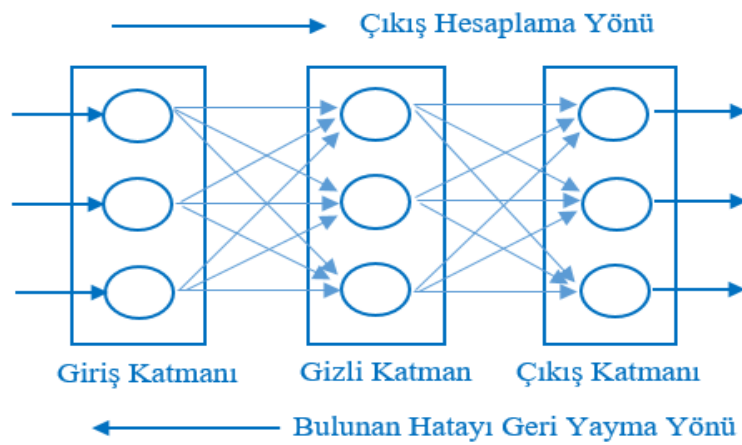


Şekil 4.3. İleri beslemeli YSA yapısı

İleri beslemeli YSA’larda, nöronlar bir döngü oluşturmazlar. Giriş katmanından gizli düzeyler olarak bilinen bir veya daha fazla ara düzeyden çıkış katmanına bir yönde akarlar. Ayrıca, belirli bir katmandaki her nöron, bir sonraki katmandaki tüm nöronlara bağlanır, ancak aynı katmandaki nöronlar arasında bir bağlantı yoktur. Birden fazla gizli katmana sahip YSA’lara derin YSA’lar denir ve karşılık gelen öğrenme algoritması genellikle derin öğrenme olarak adlandırılır. İleri beslemeli YSA’lar doğrusal olmayan sınıflandırma ve regresyon problemleri için uygundur. Prensipte olarak, farklı seviyeler için farklı aktivasyon fonksiyonları uygulayabiliriz. Uygulamada, tüm gizli katmanlar tipik olarak aynı etkinleştirme işlevini kullanır; bu genellikle sigmoidal aktivasyon fonksiyonudur. Regresyon problemlerinde, çıkış katmanındaki aktivasyon fonksiyonuna gerek yoktur; başka bir deyişle, kimlik aktivasyon işlevini kullanabiliriz [46].

4.1.1.4. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli sinir ağı çıkış ve ara katlardaki çıkışlardan önceki ara katmanlara veya giriş birimlerine geri beslenmenin yapıldığı bir yapay sinir ağıdır. Bu tür sinir ağlarının hareketli hafızaları vardır. Şekil 4.4’de Geri Beslemeli YSA yapısı gösterilmiştir. Bu yapıdaki nöronların çıkışı sadece o anki giriş değerlerine bağlı değildir ayrıca önceki giriş değerlerine de bağlı olduğundan dolayı bu ağ yapısı özellikle tahmin uygulamaları için kullanılır. Bu ağlar özellikle çeşitli tipteki zaman serilerinin tahmininde oldukça başarılıdır [45].



Şekil 4.4. Geri beslemeli YSA yapısı

İleri beslemeli YSA'lerden farklı olarak geri beslemeli YSA'larda bir nöronun çıktısı sadece kendinden sonra gelen katmana girdi olarak verilmeyip, kendi katmanında veya kendinden önceki katmanda bulunan herhangi bir nörona girdi olarak bağlanmaktadır. Bu özelliğinden dolayı geri beslemeli YSA doğrusal olmayan hareketli bir tutum göstermektedir. Aynı yapay sinir ağıyla farklı davranışta ve yapıda geri beslemeli yapay sinir ağlarını, geri besleme özelliğini kazandıran bağlantıların bağlantı şekilleriyle elde etmek mümkündür [47].

4.2. Makine Öğrenimi

Makine öğrenimi genellikle YZ'nin bir alt alanı ve hatta bazı açılardan bilgisayar biliminin bir alt alanı olarak kabul edilir. Makine öğrenimi, bazı durumlarda doğru tahminleri ve tepkileri formüle etmek için bilgisayar algoritmalarının incelenmesidir. Makine öğrenimi, ilgili verileri seçerek ve bu verileri sistemin benzer veya farklı senaryolarındaki davranışını tahmin etmek için kullanarak farklı kaynaklardan gelen verileri analiz etmemize izin veren programların geliştirilmesidir. Makine öğrenimi belirsiz durumları ele almak için ek zekâ ve öğrenmeye ihtiyaç duymaktadır. Makine öğrenimin; sınıflandırma veya kategorilere ayırma, regresyon, anormallik tespiti, yapılandırılmış açıklama, çeviri ve kümeleme gibi görevleri bulunmaktadır [40].

Makine öğreniminde birden fazla algoritma vardır, ancak bunlar denetimli ve denetimsiz öğrenme olmak üzere iki ana türe ayrılır. Denetimli öğrenme, belirli bir bilgi kümesinden alınan yanıtı tahmin etme, sınıflandırma ve regresyon problemlerine bölme yöntemidir. Regresyon problemleri, kontrast etkileri gibi sürekli verileri tahmin etmek için kullanılır. Denetimsiz öğrenme, bir yanıtın verilmediği ve belirli bir veri kümesi için benzer nesnelere bir araya getirme sürecinin olduğu denetimsiz bir sorundur [48].

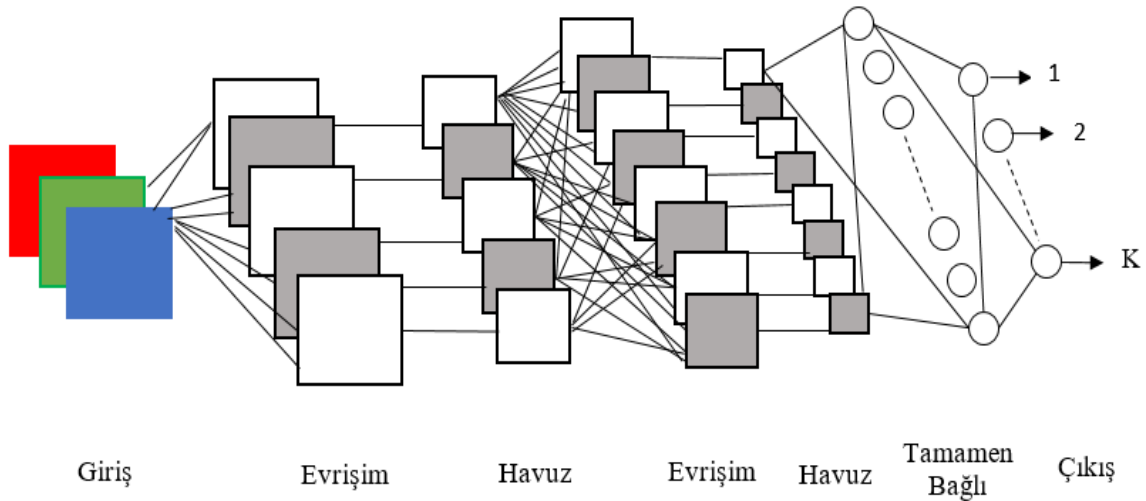
4.3. Derin Öğrenme

Derin öğrenme, Yapay Sinir Ağlarının derin bir katmanıdır. Derin öğrenme üçten fazla katman içeren bir sinir ağının, nöronların sayısına bağlı bir doğrulukla keyfi bir fonksiyona yaklaşabileceği anlamına gelen evrensel yaklaşım teoremidir. Birçok nörona sahip olan derin öğrenme yöntemi tüm işlevleri yüksek doğrulukla tahmin edebilir. Ayrıca derin

öğrenme iyi bir boyut azaltma yöntemi olarak kullanılabilir. Derin öğrenme ile gizli katman düğümlerinin sayısını azaltarak daha az boyutta görüntü özelliklerini çıkarmak mümkündür. Her bir derin öğrenme türü, her veri için uygun boyutsal sıkıştırma gerçekleştiren görüntü verileri için bir evrişimli katman ve bir havuzlama katmanı içerir. Derin öğrenmenin görüntü, metin ve müzik gibi karmaşık verileri işleyebilmesinin nedeni budur. Derin öğrenme radyoloji alanında da görüntü sınıflandırma, görüntü kalitesini ve bölütlemeyi iyileştirmede kullanılmaktadır. Evrişimli Sinir Ağı, Tekrarlayan Sinir Ağları, Uzun Kısa Süreli Bellek Ağları ve görüntü işleme için U-Net gibi çeşitli derin öğrenme türleri vardır. İşlenecek verinin formatına bağlı olarak yapı bir dereceye kadar tahmin edilebilir, bundan dolayı sinir ağının yapısı belirli veriler için en uygun olarak seçilir [48].

4.3.1. Evrişimli Sinir Ağı ve Katmanları

YSA ile bir tanıma gerçekleştirebilmemiz için o veriyi özetleyen, özelliklerin yapay sinir ağlarına gösterilmesi gerekmektedir. Doğru özelliklerin tespit edilip seçilmesinde ESA ağlarında evrişim katmanları bu işi otomatik olarak yapmakta ve verinin doğrudan kendi girişine vermektedir. Bu da bu ağ yapısını kullanmayı kolaylaştırmaktadır. Evrişimli bir ağda bulunan katmanlar Şekil 4.5’de gösterilmiştir.



Şekil 4.5. Evrişimli sinir ağı katmanları

Evrişimli bir ağ; Giriş, Evrişim Katmanı, Havuzlama Katmanı ve sınıflandırma katmanlarından oluşmaktadır. Gizli katman bir evrişim katmanı ve bir havuz katmanı içermektedir. Evrişim katmanı çevrelenen özellikleri yakalamaktan, havuz katmanı ise bunları azaltmaktan sorumludur. Evrişimli ağ da aslında bir yapay sinir ağı niteliğinde olmasına rağmen aralarındaki fark yapay sinir ağlarında evrişim ve havuzlama katmalarının bulunmasıdır. Evrişimli Sinir Ağında esas olan görüntü farklılaştırma için kullanılan bir tür derin öğrenmedir [49].

ESA, uçtan uca bir öğrenme modeli sağlar ve derin öğrenmede yaygın olarak kullanılır. Modeldeki parametreler gradyan iniş algoritmasıyla eğitilebilir ve eğitilen evrişimli sinir ağı, verilerin özelliklerini öğrenebilir. Orijinal veriler doğrudan girdi olarak kullanılabilir ve bu da verilerin ön işleminde karmaşıklığı önleyebilir. Evrişim işlemi, modelin karmaşıklığını ve hesaplama miktarını büyük ölçüde azaltan ağın ağırlığını paylaşır. ESA'nın en önemli kısmı evrişim ve havuzlama işlemidir. Her evrişim katmanı, giriş karakteristik haritası üzerinde bir evrişim çekirdeğini hareket ettirerek her adımdan yerel bilgileri alırken, havuzlama katmanı, havuzlamayı, ortalama havuzlamayı ve diğer işlemleri maksimize ederek giriş karakteristik haritasının bitişik elamanlarının bilgilerini birleştirir [50].

ESA, öğrenme ağırlıkları ve ön yargıları olan nöronlardan oluşan derin bir sinir ağıdır. Tüm ağ, bir uçtaki ham pikseli diğer uçtaki sınıf değerlerine eşitleyen türevlenebilir puan işlevi gibidir. Aynen diğer sinir ağları gibi son tam bağlı katmanda softmax gibi bir kayıp fonksiyona sahip olabilir. Çok sayıda görüntüyü işlemede verimliliği yüksektir. ESA, bir veya daha fazla evrişim katmanından, tamamen birbirine bağlı katmanlardan ve havuzlama katmanlarından oluşur. Bunun böyle olması ESA'nın iki boyutlu görüntü girişinden faydalanmasına imkân tanır. Bir geri yayılım algoritması kullanmak üzere eğitilmiştir. Diğer derin ileri sinir ağlarının aksine giriş ve çıkış birimlerini bağlamak yerine, ESA komşu haritaları ortak bir parametre ile bağlar. Evrişim çekirdeği parametreleri paylaşıldığından görüntü özellikleri evrişim çekirdeğini tüm giriş görüntüsü üzerinde kaydırarak çıkarılabilir [51].

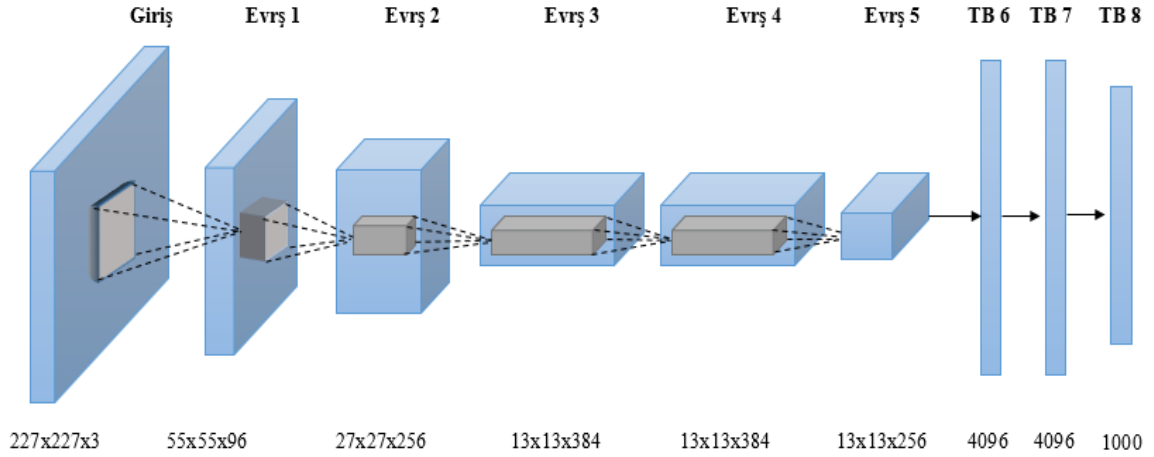
Görsel görüntüleri analiz etmek için başarıyla kullanılan ESA derin gelişmiş bir YSA'dır. İnsan görüşünden ilham alan bir ESA'nın katmanları, üç boyutta düzenlenmiş nöronlara

sahiptir, bu nedenle katmanların genişlikleri, yükseklikleri ve derinlikleri vardır. Konvolüsyon katmandaki nöronlar, tamamen bağlı nöronları boşa harcamamak için önceki katmanın yalnızca küçük bir alanına bağlanır. Son zamanlarda ESA, güç kalitesi, yük tahmini, rüzgâr alanlarındaki uzamsal özellikler ve ışınım tahmini gibi enerjiyle ilgili sorunları çözmek için kullanılmaya başlanmıştır [18].

4.3.1.1. AlexNet

Derin öğrenme mimarilerinden biri olan AlexNet, Görüntü tanımak için bilgisayarla görme algoritmalarının performansını değerlendirmeyi amaçlayan ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'na katılmak üzere tasarlanmıştır. 2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından tanıtılan evrişimli bir sinir ağıdır. 60 milyona yakın parametreye sahip ağ mimarisinde, aşırı öğrenme etkisini en aza indirgeyebilmek için doğrultulmuş doğrusal birimler, bırakma ve veri büyütme aynı anda kullanılmıştır [52]. AlexNet ağı, bir milyondan fazla görüntü üzerinde başarıyla eğitilmiş ve en yaygın olarak kullanılan Evrişimli Sinir Ağı mimarilerinden biridir. AlexNet ağı, çeşitli görüntü türleri için zengin özelliklerini öğrenebilir, bu da ağın eğitilmesi için harcanan zamana olan ihtiyacı ortadan kaldırmaktadır [53].

AlexNet ağ mimarisi Şekil 4.6'da gösterilmiş olup genel olarak bir giriş katmanı, bir çıkış katmanı, beş evrişimli katman, üç havuzlama katmanı ve üç tam bağlantılı katmandan oluşur. Ağın ilk katmanı, görüntüleri girdi olarak kullanır. Evrişim işlemiyle görüntüden özellikleri çıkarır. Daha sonrasında, önceki katmandan çıkarılan özellikler, daha gelişmiş özellikler elde etmek için başka bir evrişim işlemi gerçekleştirmek için girdi olarak kullanılır. AlexNet, aktivasyon işlevi olarak ReLU'yu, aşırı öğrenmeyi bastırmak için Dropout'u ve yetersiz uyumu bastırmak için Data Augmentation'ı kullanmıştır [54].



Şekil 4.6. AlexNet ağ mimarisi

AlexNet, çakışan maksimum havuzlamayı kullanır, böylece havuzlama katmanındaki hücreler arasında çakışan alanlar oluşturur, bu özellik doğruluğunu artırır ve aşırı uyum sorununu bir dereceye kadar önler. Normalleştirme katmanı, nöronlar arasında rekabet oluşturmak ve olumlu geri bildirim oluşturmak için kullanılır, böylece daha büyük yanıt değerlerine sahip olanlar büyür ve daha küçük yanıt değerlerine sahip olanlar küçülür ve aynı zamanda modelin genelleme yeteneği geliştirilir.

AlexNet, ortalama havuzlamanın bulanıklaştırma etkisinden kaçınmak için çakışan maksimum havuzlamayı kullanır. Ek olarak, AlexNet, adım uzunluğunun havuzlama çekirdeğinin boyutundan daha küçük olmasına izin verir, böylece havuzlama katmanının çıktısı arasında örtüşme ve kapsama olur, bu da özelliklerin zenginliğini artırır. AlexNet ayrıca veri geliştirmeyi de kullanır. Veri geliştirme yoksa çok sayıda parametreye sahip ESA, yalnızca orijinal veri miktarına bağlı olarak aşırı donanıma düşecektir. Veri geliştirmeyi kullanmak, aşırı uyumu büyük ölçüde azaltabilir ve genelleme yeteneğini geliştirebilir. Aynı zamanda, AlexNet görüntü verilerini PCA ile işler ve bir miktar gürültüyü artırmak için ana bileşen üzerinde 0,1 standart sapma ile bir Gauss pertürbasyonu yapar, böylece hata oranı tekrar azaltılabilir [55].

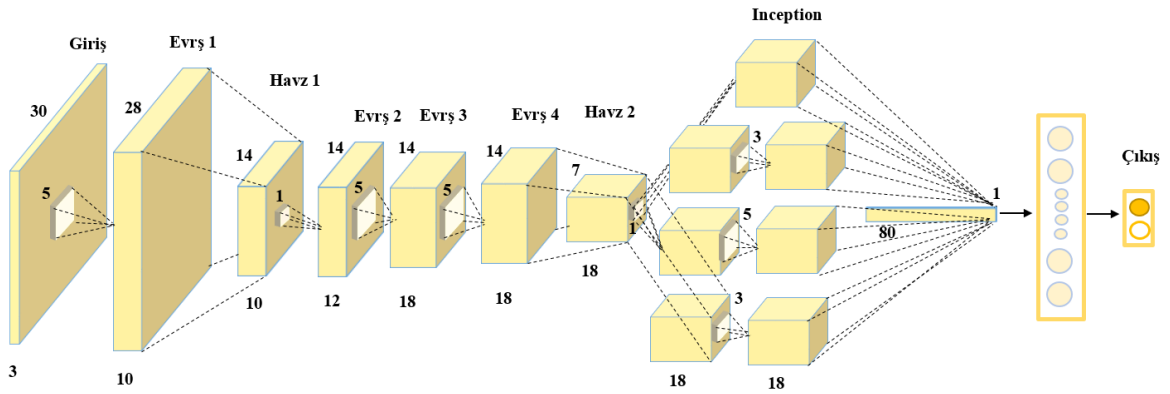
4.3.1.2. GoogleNet

GoogleNet modeli, görüntü sınıflandırma ve tanıma alanında yaygın olarak kullanılan ESA modellerinden biridir. GoogleNet modeli, yüksek sınıflandırma tanıma doğruluğuna ve az sayıda parametreye sahiptir [56].

Google tarafından 2014 yılında önerilen bir derin öğrenme yapısı olan GoogleNet, ağın derinliğini ve genişliğini artırırken ağın yapısal parametrelerini azaltan, ESA'nın derinliğinin artmasından kaynaklanan aşırı öğrenme ve gradyan dağılımı sorunlarını etkin bir şekilde çözen bir ağ modelidir [57].

Ağı tamamen genişleten bu modelin aşırı öğrenme ve hesaplama miktarını arttırmak olmak üzere iki dezavantajı bulunmaktadır. Bu modeldeki temel amaç, farklı boyutlardaki evrişimli çekirdekler yoluyla girdi örneklerinden özellikler çıkarmak ve sonrasında her bir parça tarafından elde edilen sonuçları birleştirerek, bunları ağın bir sonraki katmanına girmesini sağlamaktır [58].

Google tarafından geliştirilen ve 2014 yılında ImageNet büyük ölçekli görsel tanıma yarışmasını kazanan GoogleNet, Inception v1 olarak da bilinmektedir. Derin ağ mimarisi, farklı çekirdek boyutlarına ve havuzlama işlemlerine sahip evrişimli katmanlardan oluşan Inception modülünün kullanımı ile karakterize edilmektedir. GoogleNet genel mimarisi Şekil 4.7'de gösterilmiş olup, toplam 5 milyon parametre ile 22 katmandan oluşmaktadır. GoogleNet'in dikkat çekici özelliklerinden biri, boyutsallığı azaltma ve hesaplama verimliliği için 1 x 1 evrişimlerinin kullanılması nedeniyle diğer modellere göre düşük maliyetli olmasıdır [59].



Şekil 4.7. GoogleNet modeli ağ mimarisi

4.3.1.3. ResNet50


Artık ağ anlamına gelen ResNet50, He ve arkadaşları tarafından geliştirilmiş bir ESA çeşididir. Bir ortalama havuz katmanı, bir maksimum havuz katmanı ve 48 evrişimli katman olmak üzere 50 katmandan oluşan ResNet 50 ismini buradan almıştır [60].

ResNet, Çıktı özellik haritasının boyutundan bağımsız olarak, her katmanda aynı sayıda filtre olması ve özellik haritasının boyutu yarıya indirildiğinde her katmanın zaman karmaşıklığını korumak için iki kat daha fazla filtreye sahip olması şeklinde iki temel ilkeyi takip etmektedir. ResNet için yapı taşı, parametrelerin miktarını ve matris çarpımlarını azaltan bir darboğaz tasarımı kullanılmaktadır. Bu her katmanı eğitmeyi önemli ölçüde daha hızlı hali getirmektedir. İki katman kullanmak yerine, üç katmandan oluşan bir yığın kullanılmaktadır [61].

Artık ağlar olarak da bilinen ve adını oluşturduğu katman sayısından alan ResNet 50 diğer ağ modellerine kıyasla ek bir kimlik haritası içerir ve bir katmandan diğerine son tahmin için ResNet modeli tarafından tahmin edilir. ResNet 50, gradyan akışına ve kaybolan gradyan problemini çözmeye izin veren alternatif bir yol oluşturur. Yine ResNet diğer ağ modelleri ile kıyaslandığında diğer modellere göre daha derin ve tamamen bağlı katmanlar nedeniyle küçük bir genel mimariye sahiptir. ResNet50 dikkate alındığında, alt uzay değeri mükemmeldir. Ancak özellik alt uzayında örtüşme olasılığı vardır. Eğitim ve test aşamasında bu yeteneklerin kullanılması, belirli sınıflar için alt uzay hata değerinin

değişmesine neden olur. ResNet50 daha sık aralıklarla daha uzun eğitim süresine ihtiyaç duymaktadır [62].

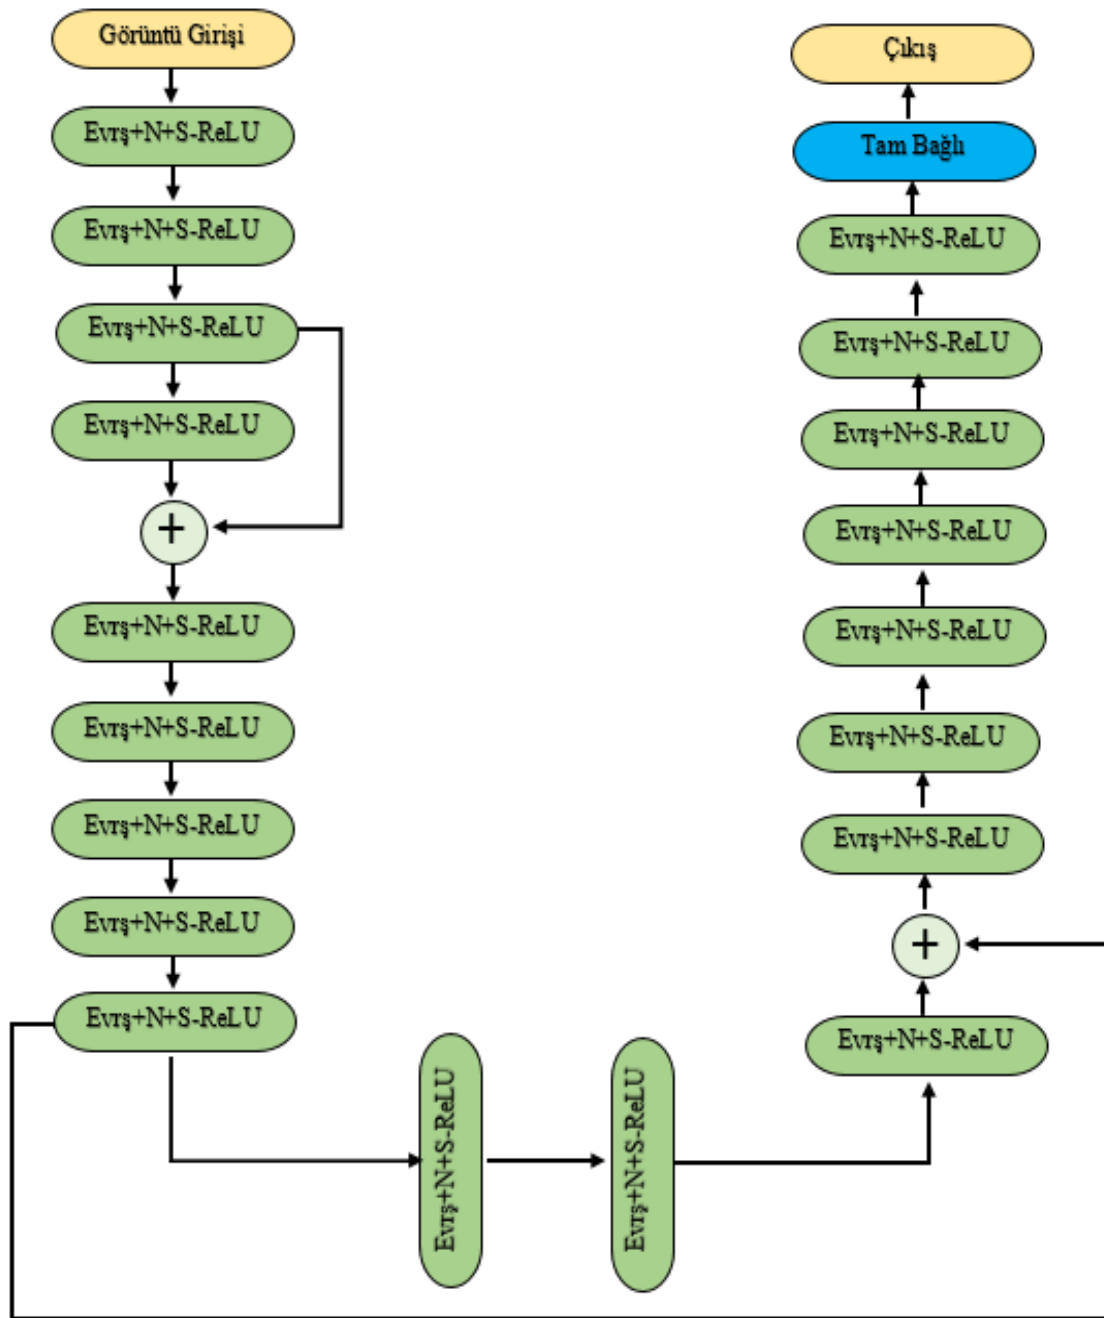
Şekil 4.8’de ResNet50’nin temel yapısı gösterilmiş olup, temel olarak beş bölümden oluşmaktadır. Birinci bölüm görüntünün özelliklerini ayıklamak ve taramak için görüntünün yeniden boyutlandırılmasından, normalleştirilmesinden ve etkinleştirme işlevinin maksimum havuzlama katmanıyla uygulanmasından sorumlu olan ön işleme aşamasıdır. İkinci bölümden beşinci bölüme kadar, modelin temel bölümünü oluşturur ve her aşamada evrişim bloğu ve kimlik bloğu olmak üzere iki temel bloktan oluşmaktadır. Evrişim bloğu ve kimlik bloğu, görüntüdeki özellik bilgilerini daha derin bir şekilde ayıklamak ve öğrenmek için birlikte çalışır [63].



Şekil 4.8. ResNet50 modelinin mimari yapısı

4.3.1.4. Önerilen ESA Model Mimarisi

Tasarlanan ağı yapısı, 19 evrişim katmanı, 1 tam bağlı katman ve 1 regresyon katmanı olmak üzere 21 katmandan oluşturuldu. Tasarlanan ağı ayrıntılı mimarisi Şekil 4.9’da gösterilmiştir. Ayrıca tasarlanan ağı ayrıntılı katman konfigürasyonu Tablo 4.1’de gösterilmiştir.



Şekil 4.9. Tasarlanan ağıın mimarisi

Tablo 4.1. Tasarlanan ađın ayrıntılı katman konfigürasyonu

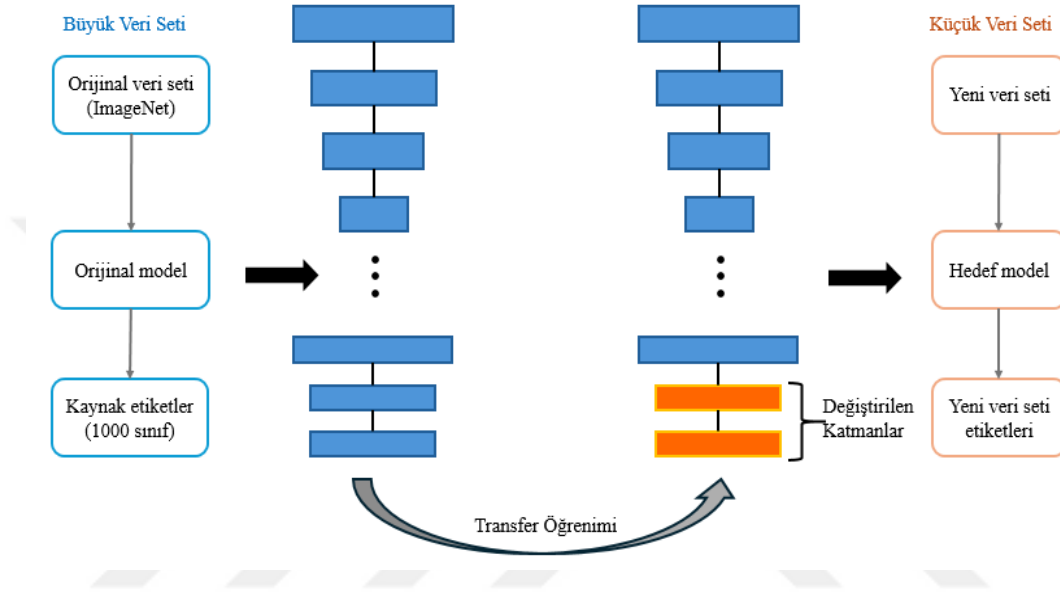
Katman Adı	Filtre Sayısı	Boyut/Adım	Çıktı
Girdi	-	-	256x256x3
Evrişim-1	32	3x3	256x256
Evrişim-2	64	3x3	128x128
Evrişim-3	128	3x3	64x64
Evrişim-4	64	1x1	64x64
Evrişim-5	128	3x3	64x64
Evrişim-6	256	3x3	32x32
Evrişim-7	128	1x1	32x32
Evrişim-8	256	3x3	32x32
Evrişim-9	512	3x3	16x16
Evrişim-10	256	1x1	16x16
Evrişim-11	512	3x3	16x16
Evrişim-12	256	1x1	16x16
Evrişim-13	512	3x3	16x16
Evrişim-14	1024	3x3	8x8
Evrişim-15	512	1x1	8x8
Evrişim-16	1024	3x3	8x8
Evrişim-17	512	1x1	8x8
Evrişim-18	1024	3x3	8x8
Evrişim-19	1000	1x1	8x8
Tam Bağlı	1	1x1000	1x1
Çıktı	-	-	1x1

4.4. Transfer Öğrenimi

Önceden eğitilmiş modellerin bilgi açısından zengin bir bölümden, verilerin sınırlı olduğu farklı bir bölümdeki görevlere uygulanmasına olanak sağlayan transfer öğrenimi başka bir ifadeyle, model eğitime yeniden başlamak yerine önceden eğitilmiş modellerin ve öğrenilen özelliklerin kullanılmasına olanak sağlamaktadır [64], [65].

Transfer öğrenimin temel amacı doğrusal olmayan süreçlerde veri toplamının zor olduğu makine öğrenimi modelleri için karşılaşılan veri eksikliğini gidermektir. Transfer öğrenimde, öncelikle hedeflenen modelle benzer konfigürasyona sahip bir kaynak seçilir. Seçilen kaynaktan yeterli miktarda veri elde edilir. Daha sonra, yeterli kaynak veri kullanılarak, istenen doğruluğu elde eden önceden eğitilmiş bir model geliştirilir ve daha sonra transfer öğrenme yöntemi kullanılarak hedef sürece uygulanır [66].

Öğrenme performansını arttırmak ve dış bilgileri kullanmak için kullanılan bir teknik olarak bilinen transfer öğreniminin önceden eğitilmiş modelden elde edilen bilgileri kullanması, hedef bir sürece kolayca uyarlanabilen önceden eğitilmiş bir modelin nasıl oluşturulacağı bu yöntemin uygulanmasındaki temel zorluktur. Çalışmamızda önerilen model için transfer öğrenimi Şekil 4.10'de gösterilmiştir.



Şekil 4.10. Transfer öğrenimi

4.5. Sürekli Dalgacık Dönüşümü

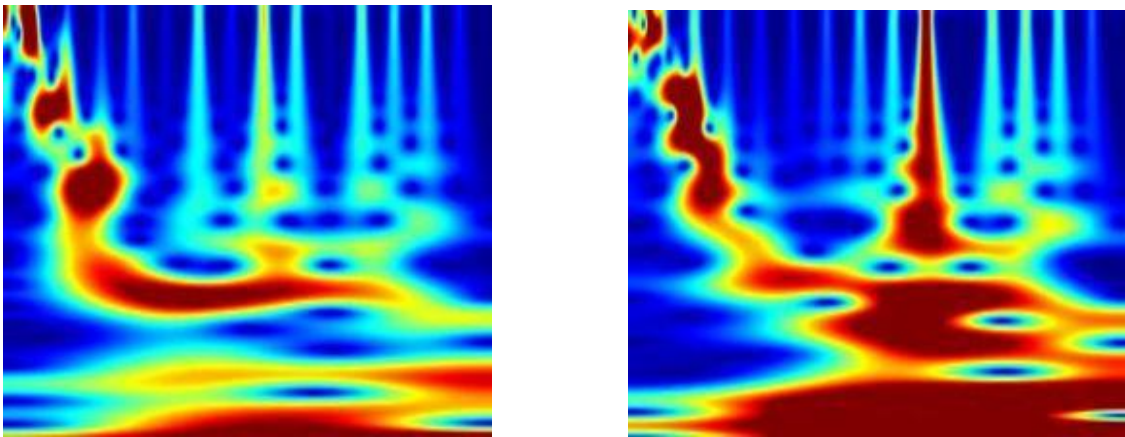
Sürekli Dalgacık Dönüşümü (SDD), sinyalleri dalgalanmalara ayırmak ve hareketli sinyallerin değişen özelliklerini planlamak için kullanılan bir sinyal işleme aracıdır. SDD, bazı belirli özellikleri karşılayan, ana dalgacık adı verilen belirli bir fonksiyona göre tanımlanır. Ancak her fonksiyon ana dalgacık olarak nitelendirilememektedir. Bir sinyal dönüşümü yapabilmek için ana dalgacığın dönüşümün ters çevrilebileceği şekilde tasarlanması gerekmektedir. Ayrıca orijinal sinyali SDD'den kurtarmaya izin veren bazı dönüşümler gereklidir. SSD'nin uygulanması dönüşümün ters çevrilmesine ihtiyaç duymasa bile SDD üzerindeki sinyal bilgilerinin kaybolmaması için SSD'nin tersinirliği gereklidir. SSD üzerinde sinyallerin mevcut olması halinde sinyal bilgileri yeniden yapılandırılabilir veya yeniden düzenlenebilir.

Ana dalgacık tarafından sağlanması gereken en önemli özellik, ters dalgacık dönüşümünün var olması için gerekli olan kabul edilebilirlik koşuludur. Bu koşul ana dalgacığın fourier dönüşümünün 0 frekansında 0 olduğunu ima etmektedir. Buda ana dalgacığın DC eğilimin olmadığını ve bu nedenle bant geçiren filtre olarak görev yapabilmesi için salınımlara sahip olması gerektiğini göstermektedir [67].

Bir sinyalin dalgacık dönüşümü f dalgacık ile ψ şeklinde Denklem 4.1'de gösterilmiştir [67].

$$W_{\psi}f(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \psi\left(\frac{b-x}{a}\right) dx \quad (4.1)$$

Dalgacık, sonlu uzaysal ve zamansal alanlarda meydana gelen çok ölçekli durağan ve durağan olmayan süreçleri incelemek için kullanılabilen matematiksel bir fonksiyondur. Matematiksel fonksiyon, sonsuzca uzanan fourier serisinin aksine sonlu küçük bir dalga biçimini temsil etmektedir. Dalgacık analizi, sismik sinyal tespiti, atmosferik türbülans, görüntü işleme, optik, veri sıkıştırma, simülasyon, kuantum mekaniği, kaos, ve tıbbi araştırmalar gibi çeşitli bilimsel alanlarda yaygın olarak kullanılmaktadır. Dalgacıklar ayrıca toprak biliminde tek boyutlu mekânsal alanların analizinde de kullanılmaktadır [68]. Şekil 4.11'de çalışmamızda elde ettiğimiz sürekli dalda dönüşümü gösterilmiştir.



Şekil 4.11 Sürekli dalgacık dönüşümü

SDD, durağan olmayan sinyallerin değişen özelliklerini haritalamak için mükemmel bir araçtır. Ayrıca bir sinyalin küresel anlamda durağan olup olmadığını belirlemek içinde

kullanılmaktadır. Bir sinyalin durağan olmadığına karar verildiğinde, SDD, veri akışının sabit bölümlerini tanımlamak için kullanılabilir [69].

Bir sismik sinyal, Fourier Dönüşümü kullanılarak zamandan frekans alanına dönüştürülmek istendiğinde, zaman - frekans kayıplarına neden olmaktadır. Bu kayıpları önlemek için sinyali genlik-zaman alanından genlik, zaman ve frekans alanına dönüştüren seçilen bir zaman penceresine göre tüm sinyali bölümlere ayıran ve her sinyal bölümü için Fourier Dönüşümünü hesaplayan Kısa Zamanlı Fourier Dönüşümü kullanılmaktadır. Kısa Zamanlı Fourier Dönüşümü yönteminin temel sınırlaması, sonuçların seçilen pencere boyutuna duyarlı olmasıdır ve bu boyutun tüm sinyal için aynı kalması gerekir. Kayıpları önlemek için bir diğer yöntem ise giriş sinyalinin çoklu çözünürlükte ayrıştırılmasını sağlayan Sürekli Dalgacık Dönüşümüdür. SDD için en önemli faktörlerden biri, sinyal ayrıştırma için kullanılan, ana dalgacık adı verilen uygun dalgacığın seçimidir. Çok sayıda dalgacık fonksiyonu bulunmaktadır. Doğru seçim, sinyalin doğasına ve ilgilenilen özelliklere bağlıdır. SDD bağlamındaki ana dalgacık; ölçeklendirme ξ ve zaman kaydırma ϑ olmak üzere iki işlemle parametrelendirilir. ξ ölçeğindeki ve kayma ϑ ' da ki bir sinyalin $s(t)$ SDD'si integral Denklem 4.2'de ifade edilmiştir.

$$Z(\xi, \vartheta) = \frac{1}{|\xi|^{1/2}} \int_{-\infty}^{\infty} S(t) \psi\left(\frac{t - \vartheta}{\xi}\right) dt \quad (4.2)$$

Denklem 3.2'de $Z(\xi, \vartheta)$, (ξ, ϑ) noktasındaki SDD katsayısı, ψ ise ana dalgacık olarak ifade edilmektedir. Ayrıca başlangıç fonksiyonu $\Gamma(t)$ 'yi kurtarmak için Ters Sürekli Dalgacık Dönüşümleri Denklem 4.3'de ifade edilmiştir.

$$\Gamma(t) = \gamma_{\psi}^{-1} \int_{-\infty}^{\infty} \int_0^{\infty} Z(\xi, \vartheta) \frac{1}{|\xi|^{1/2}} \psi\left(\frac{t - \vartheta}{\xi}\right) d\vartheta \frac{d\xi}{\xi^2} \quad (4.3)$$

Ters Sürekli Dalgacık Dönüşümleri, ancak ve ancak dalgacık sabitinin γ_{ψ} kabul edilebilirlik koşulunu sağlaması durumunda mümkün olabilir [70].

4.6. Veri Seti

Çalışmamızda kullandığımız veriler, Elazığ Meteoroloji Bölge Müdürlüğünden; Elazığ Bölge (17201), Sivrice (17844), Keban (17804) ve Baskil (17843) istasyonlarından 2018,2019,2020,2021 ve 2022 yıllarına ait saatlik rüzgâr hızı ve rüzgâr yönü alınmıştır. Meteorolojiden almış olduğumuz veriler Excel ortamında hazırlanmış olup, satırlar, günleri sütunlar ise saatleri göstermektedir. Alınan veriler toplamda 11835 satırdan oluşmaktadır. Şekil 4.12’de Elazığ Meteoroloji Bölge Müdürlüğünden alınan ham verilerden bir kesit gösterilmiştir.

Almış olduğumuz verilerde (Şekil 3.8) rüzgâr hızının ve rüzgâr yönünün tek satırda yazıldığını ve rüzgâr yönünün; (N) Kuzey, (NNE) Kuzey-Kuzeydoğu, (NE) Kuzeydoğu, (ENE) Doğu-Kuzeydoğu, (E) Doğu, (ESE) Doğu-Güneydoğu, (SE) Güneydoğu, (SSE) Güney-Güneydoğu, (S) Güney, (SSW) Güney-Güneybatı, (SW) Güneybatı, (WSW) Batı-Güneybatı, (W) Batı, (WNW) Batı-Kuzeybatı, (NW) Kuzeybatı,(NNW) Kuzey-Kuzeybatı, (C) Sakin şeklindedir.

Yıl/Ay: 2018/1 İstasyon Adı/No: ELAZIĞ BÖLGE/17201																								
Saatlik Rüzgar Yönü ve Hızı (m+s-n)																								
Gün/Saat	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	ENE2.5	E 1.4	E 2.1	SE 2.3	ENE4.3	E 5.0	E 4.4	E 3.8	ESE3.3	E 3.3	E 2.7	E 2.9	ESE1.9	WNW0.7	N 0.2	NNE0.2	N 1.9	NNW1.0	WNW3.1	WNW3.2	W 2.1	WNW5.1	WNW4.3	WNW2.3
2	W 0.7	NNE0.3	WNW0.7	NW 0.9	SW 0.7	W 1.4	NW 0.8	SSW1.5	W 4.0	WNW5.2	WNW5.4	WNW5.2	WNW4.9	WNW3.9	NW 3.6	WNW1.9	NNW0.8	NW 1.9	NNW2.4	NW 1.8	N 0.8	NW 2.3	NW 2.6	NW 2.3
3	NW 1.8	NW 1.9	NNW1.8	NW 1.8	NW 1.5	NNW1.3	NW 0.9	SE 1.0	SE 1.8	SSE2.2	SSE2.0	ESE2.9	ESE1.9	ESE3.3	SSE1.1	NE 0.6	ENE2.0	E 2.1	E 3.3	ENE3.6	ENE3.6	E 4.1	E 4.8	ESE5.0
4	E 5.5	E 4.2	ENE3.8	E 4.4	E 4.6	E 4.0	E 4.4	E 6.0	E 6.0	E 6.9	E 5.2	ENE3.5	ENE3.8	E 4.1	ENE4.6	E 4.9	E 3.5	E 3.2	E 2.8	E 3.8	ESE3.4	ESE4.1	E 4.2	E 4.9
5	E 5.4	E 4.9	E 5.6	E 5.7	E 6.3	E 5.2	E 4.5	E 5.0	E 6.1	E 5.0	E 3.0	E 1.9	ESE2.0	E 3.1	E 3.6	E 2.7	ENE2.9	ENE2.9	ENE3.3	ENE2.5	N 0.8	NNW1.6	NNW1.5	NW 1.2
6	NNW1.8	NNW1.8	NW 1.8	NW 1.8	NNW1.8	NW 1.7	WNW1.2	NNE0.5	ESE1.6	SSW1.8	NW 2.3	W 3.0	WNW3.1	WNW3.0	NW 2.2	NNW0.6	NW 1.8	NW 2.0	NNW2.1	NNW2.5	NNW1.6	NNW1.4	NNW1.3	NW 1.5
7	NW 2.3	NNW1.8	NNW0.9	NW 1.5	NW 2.4	NW 2.0	NNW0.6	NE 0.9	NW 0.7	SW 1.5	W 2.3	W 1.8	WSW2.0	WSW1.8	SW 1.6	W 1.8	NW 2.3	NW 2.6	NW 2.4	NW 2.4	NW 2.8	NNW2.1	NNW1.6	NW 2.6
8	NW 1.8	NW 1.8	NW 2.0	NW 1.8	NW 1.5	NW 1.5	NNW0.8	NE 0.4	SE 1.3	SSE2.0	SE 1.7	SE 2.0	SE 1.9	SE 1.4	ESE1.3	NNW0.7	NNW1.4	NW 2.0	NW 2.2	NW 2.6	NW 2.6	NW 2.3	NW 2.1	NNW0.5
9	NW 1.7	N 0.1	NNW1.5	NNW0.8	NW 1.3	NNW1.2	NNW0.7	SSW0.7	SSE1.6	SSE2.2	SE 1.9	SE 1.6	SE 1.7	SE 1.7	SE 0.9	NNW1.9	NNW1.9	NW 1.7	N 0.4	N 0.5	NW 1.8	NNW1.1	WNW0.9	NW 1.6
10	NW 2.6	NW 2.7	NW 2.8	WNW2.0	NW 2.2	NNW1.6	NW 1.3	ENE0.6	WNW0.6	WNW2.1	WSW2.2	NNW1.2	ESE2.3	E 2.4	ENE1.4			NNW2.1	NW 2.0	NNW1.7	NW 1.5	N 0.9	N 0.2	
11				N 0.2		NNE1.0	ENE0.7	NNW0.5	SSE1.8	SSE1.9	SE 1.6	SE 1.8	ESE3.1	E 6.6	E 4.6	E 4.3	ENE3.9	ENE3.1	ENE3.5	ENE3.3	SE 0.9	NW 1.3	NNW1.5	WNW1.4
12	NW 1.4	NNW0.8	N 0.3	NW 1.0	NW 0.9	NW 1.3	NW 1.3	S 1.0	SW 0.8	SE 2.3	SSE2.4	SE 2.0	SE 1.8	SE 1.3	N 0.4	ESE1.1	ESE0.8	NNE0.7	NNW0.2	NNW0.4	N 0.3	NNW1.5	NNW1.3	NNW0.5
13	NNW0.8	NNW0.7	NNW1.5	NNE1.0	N 0.5	WNW0.8	N 0.3	SSE1.8	SE 1.1	SSE1.6	SSE2.0	SE 2.3	ESE2.0	ESE1.7	NNE0.4		NE 0.9	SE 0.6	NNE0.8	ENE2.5	NNW1.2	NW 1.1	NW 1.2	NW 1.5

Şekil 4.12. Elazığ iline ait ham rüzgâr verileri

4.6.1. Veri Setinin Düzenlenmesi

Elazığ Meteoroloji Bölge Müdürlüğünden Elazığ merkez ve Elazığ ilinin üç ilçesine ait alınan verilerden çalışmamızda sadece Elazığ Merkezine ait 2018 ve 2019 yıllarına ait veriler kullanılmıştır. Çalışmamız rüzgâr hızı ile tahmin üzerine yapıldığı için veri seti üzerinde bulunan rüzgâr yönleri silinerek veri seti yeniden düzenlenmiştir. Ayrıca Excel dosyasında satırlar arasında bulunan boş satırlar, açıklamalar, yazılar ve logolar kaldırılarak veri seti daha düzenli bir hale getirilmiştir (Şekil 4.13).

Date	0:00:00	1:00:00	2:00:00	3:00:00	4:00:00	5:00:00	6:00:00	7:00:00	8:00:00	9:00:00	10:00:00
January 1, 2018	2.5	1.4	2.1	2.3	4.3	5.0	4.4	3.6	3.3	3.3	2.7
January 2, 2018	0.7	0.3	0.7	0.9	0.7	1.4	0.8	1.5	4.0	5.2	5.2
January 3, 2018	1.8	1.9	1.8	1.8	1.5	1.3	0.9	1.0	1.8	2.2	2.0
January 4, 2018	5.5	4.2	3.8	4.4	4.6	4.0	4.4	6.0	6.0	6.9	5.2
January 5, 2018	5.4	4.9	5.6	5.7	6.3	5.2	4.5	5.0	6.1	5.0	3.0
January 6, 2018	1.8	1.8	1.6	1.6	1.8	1.7	1.2	0.5	1.6	1.8	2.3
January 7, 2018	2.3	1.8	0.9	1.5	2.4	2.0	0.6	0.9	0.7	1.5	2.3
January 8, 2018	1.8	1.6	2.0	1.6	1.5	1.5	0.8	0.4	1.3	2.0	1.7
January 9, 2018	1.7	0.1	1.5	0.8	1.3	1.2	0.7	0.7	1.6	2.2	1.9
January 10, 2018	2.6	2.7	2.8	2.0	2.2	1.6	1.3	0.6	0.6	2.1	2.2
January 11, 2018	0.2	0.2	0.2	0.2	0.5	1.0	0.7	0.5	1.8	1.9	1.6
January 12, 2018	1.4	0.8	0.3	1.0	0.9	1.3	1.3	1.0	0.8	2.3	2.4
January 13, 2018	0.8	0.7	1.5	1.0	0.5	0.8	0.3	1.6	1.1	1.6	2.0
January 14, 2018	0.9	2.5	1.5	1.6	3.8	1.0	1.6	3.2	4.0	5.0	4.4
January 15, 2018	0.5	0.6	1.8	1.9	2.0	2.0	2.0	1.9	1.2	1.3	1.5

Şekil 4.13. Elazığ iline ait düzenlenmiş rüzgâr verileri

4.7. Performans ve Değerlendirme Ölçütleri

Rüzgâr hızının tahmini, rüzgâr çiftliklerinin verimli çalışması ve şebeke stabilizesi için büyük önem arz etmektedir. Rüzgâr hızının rastgele olması, rüzgâr hızının doğru tahmini için büyük bir zorluk teşkil etmektedir. Bu sebeple çalışmamızda tahmin performans ölçütleri olarak, karekök ortalama hata (RMSE), ortalama mutlak hata (MAE), ortalama kare hata (MSE) ve ortalama hata (ME) kullanılmıştır.

Karekök Ortalama Hata (RMSE), bir model tarafından tahmin edilen değerler ile gözlemlenen değerler arasındaki farkların yaygın olarak kullanılan bir ölçüsü olarak bilinmekte olup formülü Denklem 4.4'de gösterilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.4)$$

Denklem 4.4'de n gözlem sayısını, y_i gözlemlenen değeri, \hat{y}_i ise tahmin edilen değeri göstermektedir.

Ortalama Mutlak Hata (MAE), bir tahmin modelinin doğruluğunu değerlendirmek için yaygın olarak kullanılan bir ölçektir. Özellikle regresyon analizinde kullanılır ve bir dizi tahminin doğruluğunu ölçer. MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalaması alınarak bulunur.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.5)$$

Denklem 4.5'de n gözlem sayısını, y_i gözlemlenen değeri, \hat{y}_i tahmin edilen değeri, $|y_i - \hat{y}_i|$ ise mutlak hatayı göstermektedir.

Ortalama Kare Hata (MSE), özellikle regresyon analizinde kullanılır ve tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını temsil eder. MSE, hataların karelerini alarak büyük hataları en aza indirger. Her zaman pozitif ve sıfıra yakın değerler gösterir. Formülü Denklem 4.6'de gösterilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.6)$$

Denklem 4.6'da n gözlem sayısını, y_i gözlemlenen değeri, \hat{y}_i tahmin edilen değeri, $(y_i - \hat{y}_i)^2$ ise hataların karesini göstermektedir.

Ortalama Hata (ME), tahminlerin genel eğilimlerini göstermektedir. Pozitif bir ortalama hata, modelin tahminlerinin genel olarak düşük olduğunu, negatif bir ortalama hata ise genel olarak yüksek olduğunu gösterir. Hesaplaması ve yorumlaması kolay bir ölçektir, ancak hataların büyüklüğünü dikkate almadığı için diğer hata ölçümleri kadar yaygın kullanılmamaktadır. Ortalama hata ölçütünün formülü denklem 4.7’de gösterilmiştir.

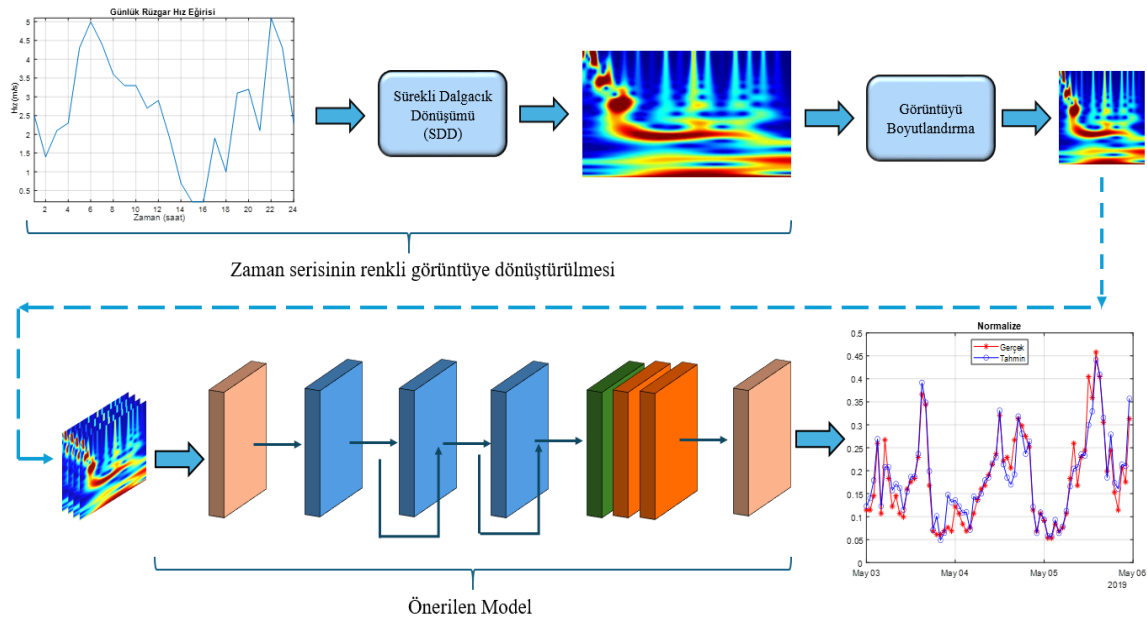
$$ME = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (4.7)$$



5. BULGULAR VE TARTIŞMA

Bu bölümde, önceki bölümde bahsetmiş olduğumuz veri seti kullanılarak rüzgâr hızı tahmini için yapmış olduğumuz deneysel çalışmalar ve bu çalışmalardan elde edilen deney sonuçları sunulmaktadır. Deneysel çalışmalar, dört çekirdekli Intel i7 işlemci, GTX 850M GPU ve 16GB hafızaya sahip bilgisayarda kurulu MATLAB (2021b) ile gerçekleştirilmiştir.

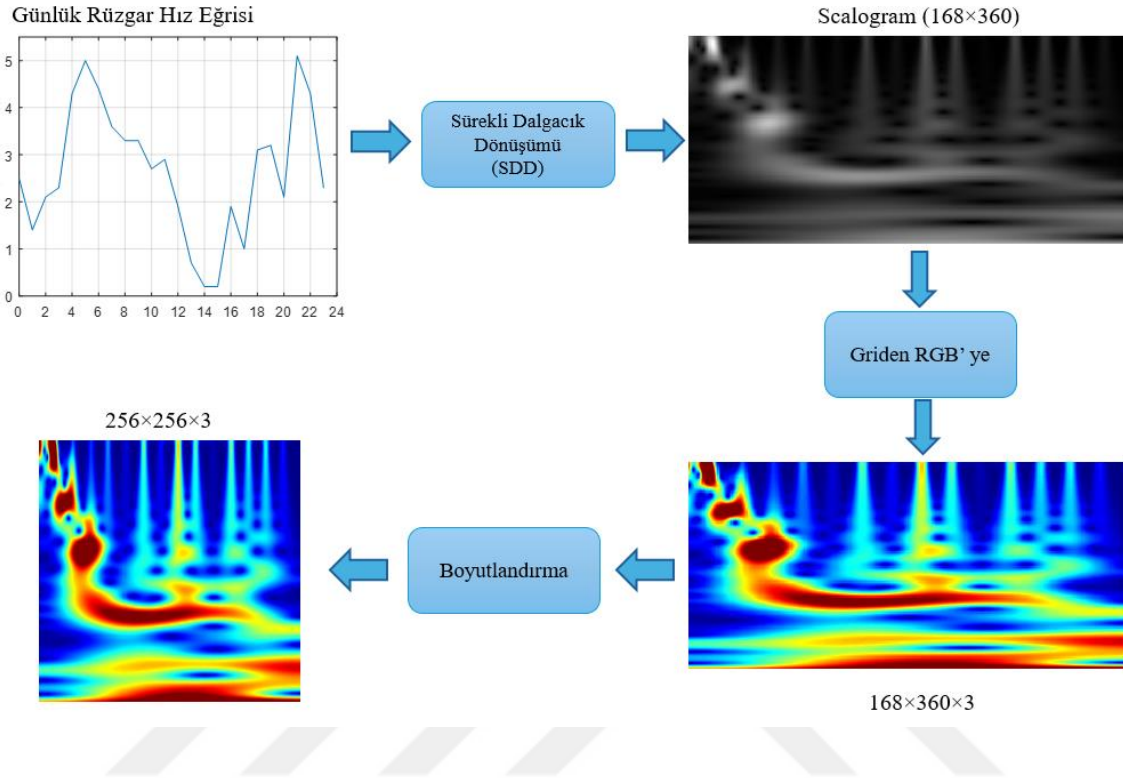
Bu çalışmada, rüzgâr hız tahmini için Şekil 5.1’de blok diyagramı gösterilen bir ESA tabanlı bir model önerilmektedir.



Şekil 5.1. Önerilen model genel yapısı

Şekil 5.1’de görüleceği gibi önerilen modelde öncelikle 2018-2019 yılları arasındaki saatlik rüzgâr hızlarını içeren zaman serileri SSD ile görüntüye dönüştürüldü. Zaman serisi sinyalleri, Şekil 5.2’de gösterildiği gibi önce 168 x 360 boyutlarında gri görüntüye dönüştürüldü. Daha sonra gri görüntüdeki piksel parlaklığı ve kontrast değerlerindeki değişimler homojen olarak değişen bir jet128 renk haritası ile renklendirilerek 168 x 360 x

3 renkli scalogram görüntüye dönüştürüldü ve son olarak önerilen model girişine uygun olarak $256 \times 256 \times 3$ olarak yeniden boyutlandırıldı.



Şekil 5.2. Zaman serilerinden scalogram görüntülerin elde edilmesi

Deneysel çalışmalarda, önerilen ESA modeline ek olarak AlexNet, GoogLeNet ve ResNet50 ESA modelleri kullanılmıştır. Deneysel çalışmalarının ilk aşamasında, tüm veri seti görüntüleri rastgele bir şekilde sırasıyla %70, %10 ve %20 oranlarında eğitim, doğrulama ve test olmak üzere üç bölüme ayrılmıştır. Eğitim veri seti önerilen modelin öğrenme sürecinde, doğrulama veri seti modeli oluşturabilmek amacıyla eğitim setinin bir parçası olarak kullanıldı. Ayrıca doğrulama veri seti ise model parametrelerinin ayarlamak için de kullanıldı. Test veri kümesi ise performans değerlendirmesi için kullanıldı.

Deneysel çalışmaların gerçekleştirildiği ESA modellerinin eğitim sürecinde modele ait en iyi parametrelerinin belirlenmesi için deneyler birkaç kez tekrar edildi. Bunun sonucunda başlangıç öğrenme oranı 0,0001, mini parti büyüklüğü 32 ve maksimum tekrar sayısı 40 olarak seçildi ve her 10 çağda 0,5 düşme faktörü öğrenme oranı ile azaltıldı. Önerilen yöntemin tahmin performansının daha doğru bir şekilde değerlendirilebilmesi için deneyler

1 saat, 2 saat ve 3 saat ileri olmak üzere farklı tahmin ufuklarına bölünmüştür. AlexNet, ResNet, GoogleNet ve önerilen ESA modelinin 1 saatlik, 2 saatlik ve 3 saatlik ileri orijinal ve normalize deneysel çalışma sonuçları performans değerlendirme kriterleri olan RMSE, MAE ve R değerleri Tablo 5.1’de sunulmuştur.

Tablo 5.1. Tahmin sonuçları

Model		Orijinal			Normalize		
		RMSE	R ²	MAE	RMSE	R ²	MAE
AlexNet	1 Saat ileri	0,8196	0,8686	0,5866	0,0626	0,8686	0,0448
ResNet50		0,8885	0,8470	0,6681	0,0678	0,8470	0,0510
GoogleNet		0,8875	0,8381	0,6530	0,0677	0,8381	0,0498
Önerilen Model		0,8058	0,8757	0,5872	0,0615	0,8757	0,0448
AlexNet	2 Saat ileri	1,0047	0,7705	0,7436	0,0767	0,7705	0,0568
ResNet50		1,1326	0,6911	0,8568	0,0865	0,6911	0,0654
GoogleNet		1,0899	0,7202	0,8168	0,0832	0,7202	0,0623
Önerilen Model		1,0532	0,7397	0,7726	0,0804	0,7397	0,0590
AlexNet	3 Saat ileri	1,2133	0,6842	0,8742	0,0926	0,6482	0,0667
ResNet50		1,3633	0,5394	1,0409	0,1041	0,5394	0,0795
GoogleNet		1,1932	0,6472	0,8635	0,0911	0,6472	0,0659
Önerilen Model		1,2589	0,6612	0,9753	0,0961	0,6612	0,0745


Tablo 5.1 incelendiğinde normalize edilmiş verilere göre, 1 saat ilerisi için, önerilen yöntemden elde edilen RMSE değeri 0,0615 iken, AlexNet 0,0626, ResNet50 0,0678, GoogleNet 0,0677 olarak hesaplanmıştır. R değerine göre önerilen model 0,8757 iken AlexNet 0,8686, ResNet50 0,8470, GoogleNet 0,8381 olarak hesaplanmıştır. MAE değerine göre ise önerilen model 0,0448 iken AlexNet 0,0448, ResNet50 0,0510, GoogleNet 0,0498 olarak hesaplanmıştır.

Normalize edilmiş verilere göre 2 saat ilerisi için, önerilen yöntemden elde edilen RMSE değeri 0,0804 iken, AlexNet 0,0767, ResNet50 0,0865, GoogleNet 0,0832 olarak hesaplanmıştır. R değerine göre önerilen model 0,7397 iken AlexNet 0,7705, ResNet50 0,6911, GoogleNet 0,7202 olarak hesaplanmıştır. MAE değerine göre ise önerilen model 0,0590 iken AlexNet 0,0568, ResNet50 0,0654, GoogleNet 0,0623 olarak hesaplanmıştır. Normalize edilmiş verilere göre 3 saat ilerisi için önerilen yöntemden elde edilen RMSE değeri 0,0961 iken, AlexNet 0,0926, ResNet50 0,1041, GoogleNet 0,0911 olarak hesaplanmıştır. R değerine göre önerilen model 0,6612 iken AlexNet 0,6482, ResNet50


0,5394, GoogLeNet 0,6472 olarak hesaplanmıştır. MAE değerine göre ise önerilen model 0,0745 iken AlexNet 0,0667, ResNet50 0,0795, GoogLeNet 0,0659 olarak hesaplanmıştır. Ayrıca Tablo 5.1'deki orijinal (gerçek) verilere göre, 1 saat ilerisi için, AlexNet, ResNet50, GoogLeNet ve önerilen yöntem için sırasıyla RMSE değerleri 0,8196, 0,8885, 0,8875 ve 0,8058, R değerleri 0,8686, 0,8470, 0,8381 ve 0,8757 ve MAE değerleri 0,5866, 0,6681, 0,6530, 0,5872 olarak elde edildi. Aynı şekilde 2 ve 3 saat ileri için AlexNet ESA modelinde RMSE değerleri sırasıyla 1,0047 ve 1,2133, ResNet50 modelinde RMSE değerleri sırasıyla 1,1326 ve 1,3633, GoogLeNet modelinde RMSE değerleri sırasıyla 1,0899 ve 1,1932 ve son olarak önerilen ESA modelinde RMSE değerleri sırasıyla 1,0532 ve 1,2589 şeklindedir. Orijinal verileri ile yapılan deneysel çalışmalarda 2 saat ilerisi için önerilen model RMSE değerlerine göre ikinci ve 3 saat ilerisi için üçüncü en yüksek başarıma sahip ESA modelidir.

AlexNet, ResNet50 ve GoogLeNet ESA yöntemlerinin orijinal veriler ile 1 saatlik ileri tahmin için elde edilen sonuçlar için sırasıyla Şekil 5.3, Şekil 5.5 ve Şekil 5.7'de, normalize edilmiş değerler için Şekil 5.4, Şekil 5.6 ve Şekil 5.8'de gösterilmiştir. AlexNet modeline ait Şekil 5.3 ve Şekil 5.4 karşılaştırıldığında normalize edilen verilere ait eğrilerin, orijinal verilere ait eğrilere göre tahmin eğrilerinin gerçek eğrilere daha iyi yakınsadığı ve bir saat ileri tahminlerde daha başarılı olduğu görülebilmektedir. Benzer bir durum ResNet50 modeline ait Şekil 5.5 ve Şekil 5.6'da ve GoogLeNet modeline ait Şekil 5.7 ve Şekil 5.8'de de görülebilmektedir.

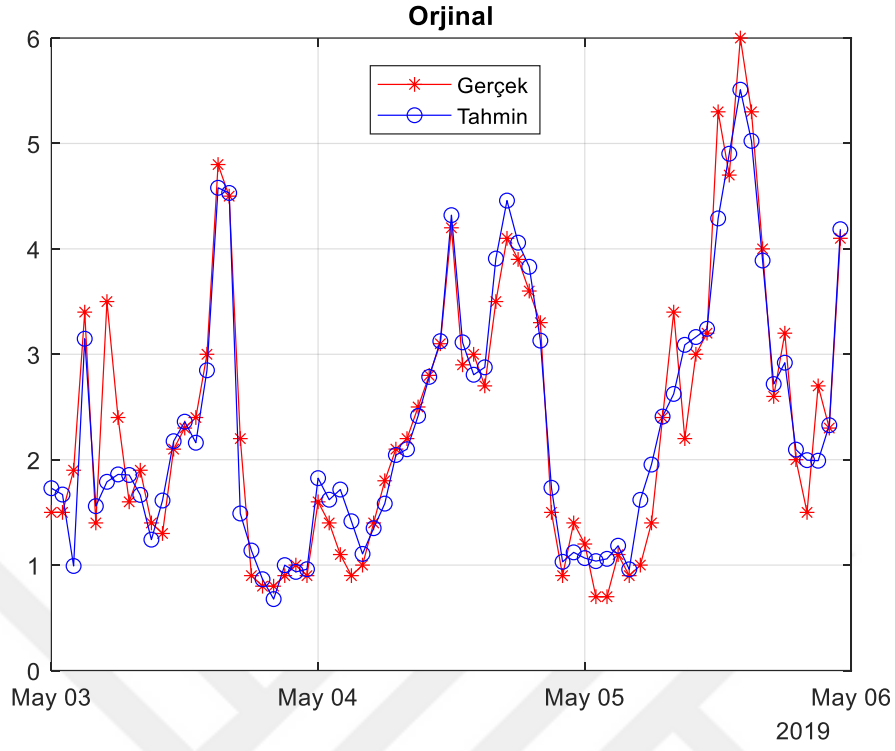
Bunun yanı sıra önerilen ESA modelinde 1 saatlik ileri, 2 saatlik ileri, 3 saatlik ileri tahminlerde elde edilen sonuçlar orijinal değerler için sırasıyla Şekil 5.9, Şekil 5.11 ve Şekil 5.13'de, normalize edilmiş değer için Şekil 5.10, Şekil 5.12 ve Şekil 5.14'te gösterilmiştir.




Şekil 5.3. AlexNet 1 saatlik orjinal sonuçlar



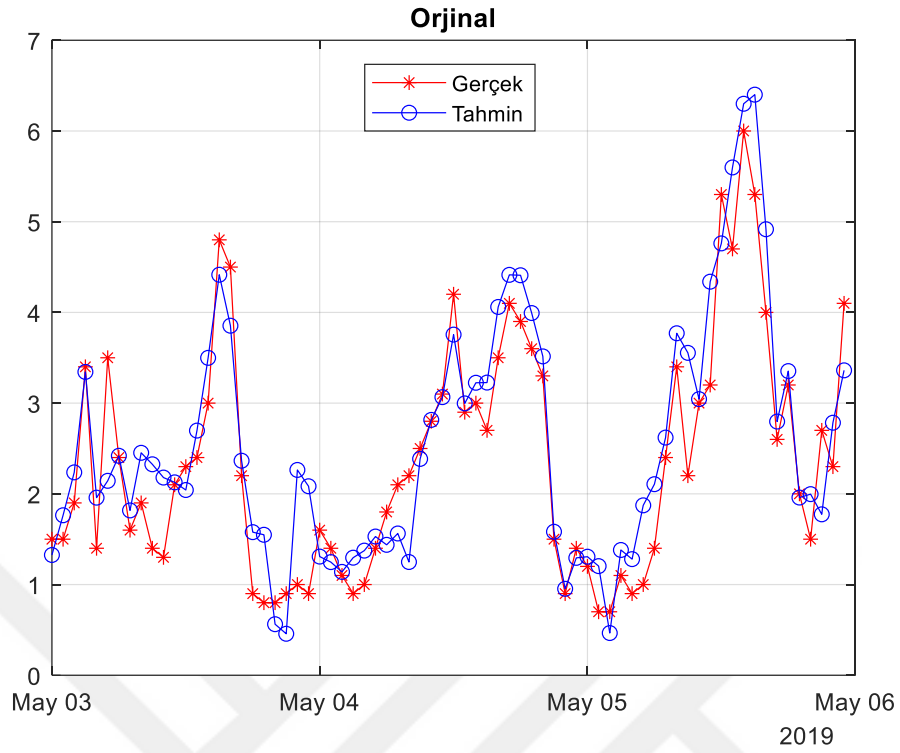
Şekil 5.4. AlexNet 1 saatlik normalize edilmiş sonuçlar




Şekil 5.5. GoogleNet 1 saatlik orijinal sonuçlar




Şekil 5.6. GoogleNet 1 saatlik normalize edilmiş sonuçlar




Şekil 5.7. ResNet50 1 saatlik orjinal sonuçlar



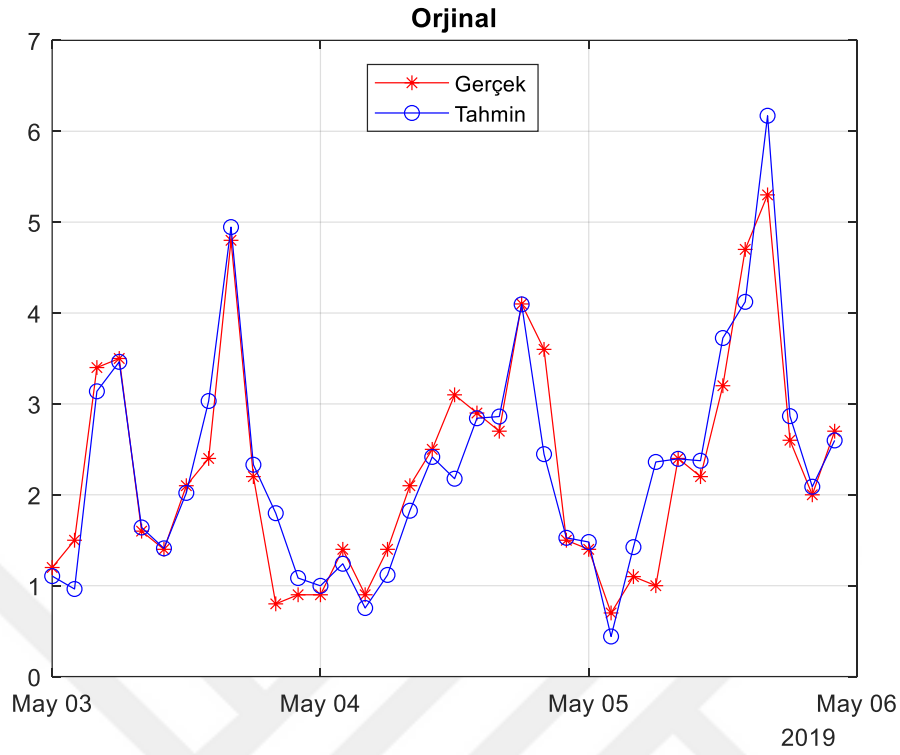
Şekil 5.8. Resnet50 1 saatlik normalize edilmiş sonuçlar



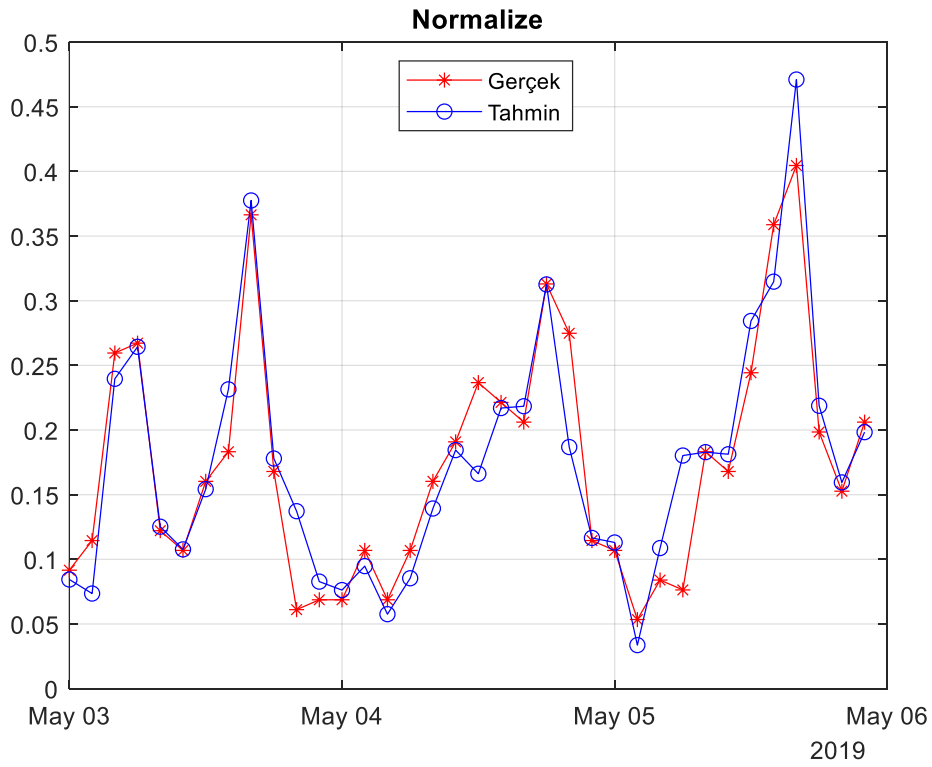
Şekil 5.9.Önerilen model 1 saatlik orjinal sonuçlar



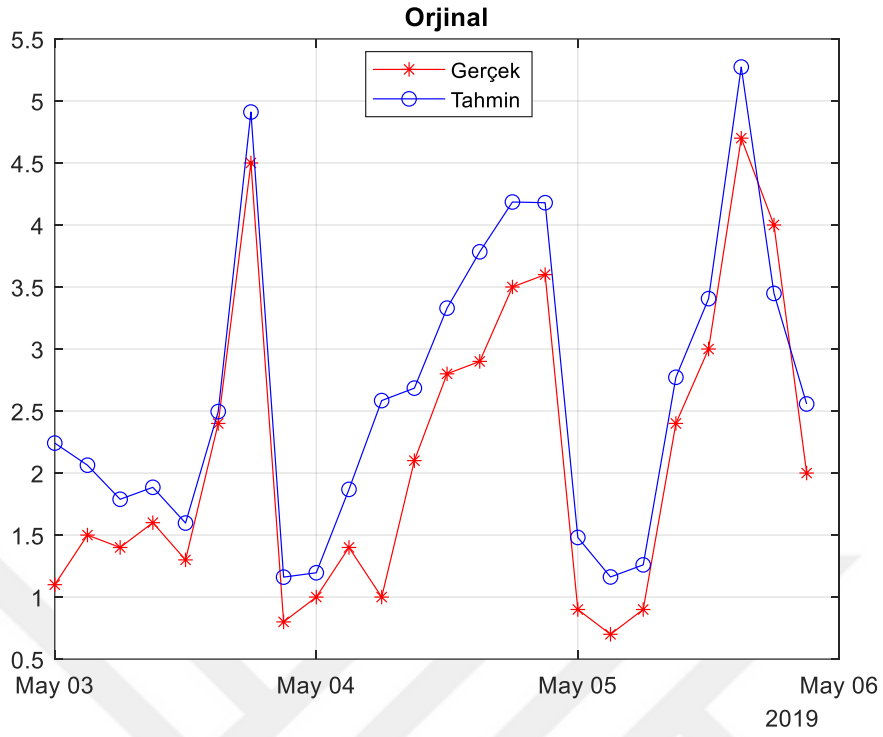
Şekil 5.10. Önerilen model 1 saatlik normalize edilmiş sonuçlar




Şekil 5.11. Önerilen model 2 saatlik orjinal sonuçlar



Şekil 5.12. Önerilen model 2 saatlik normalize edilmiş sonuçlar



Şekil 5.13.Önerilen model 3 saatlik orjinal sonuçlar



Şekil 5.14. Önerilen model 3 saatlik normalize edilmiş sonuçlar

Önerilen ESA modelinin 1, 2 ve 3 saat ileri tahminlerinde orijinal verilere ait Şekil 5.9, Şekil 5.11 ve Şekil 5.13 eğriler ile normalize edilmiş verilere ait Şekil 5.10, Şekil 5.12 ve Şekil 5.14'teki eğriler karşılaştırıldığında normalize edilmiş veriler ait eğrilerin gerçek eğrilere daha iyi yakınsadığı görülebilmektedir. Ayrıca normalize edilmiş verilere ait 1, 2 ve 3 saat ileri tahminlere ait Şekil 5.10, Şekil 5.12 ve Şekil 5.14'teki eğrileri karşılaştırıldığında 1 saatlik ileri tahminlerde tahmin edilen eğrinin gerçek eğriye daha iyi yakınsadığı ve daha yüksek oranda tahmin yapabildiği görülmektedir.

Tüm yöntemler rüzgâr enerjisinin 1 saatlik ileri tahminleri; RMSE açısından değerlendirildiğinde önerilen modelin, R açısından değerlendirildiğinde GoogLeNet, MAE açısından değerlendirildiğinde ise AlexNet ve önerilen modelin iyi bir performans sergilediği, 2 saatlik ileri tahminleri RMSE açısından değerlendirildiğinde AlexNet, R açısından değerlendirildiğinde ResNet50, MAE açısından değerlendirildiğinde ise AlexNet iyi bir performans sergilediği, 3 saatlik ileri tahminleri RMSE açısından AlexNet, R açısından değerlendirildiğinde ResNet50, MAE açısından değerlendirildiğinde ise GoogLeNet iyi bir performans sergilediği gözlemlenmiştir. Önerilen modelin 1 saatlik ileri tahminler için iyi bir performans sergilediği 2 saatlik ve 3 saatlik ileri tahminleri için AlexNet, ResNet50 ve GoogLeNet derin öğrenme ağlarının önerilen modele görev iyi bir performans sergilediği görülmektedir.

6. SONUÇLAR VE ÖNERİLER

Bu çalışmada, rüzgâr hız tahmini için derin öğrenme temelli bir yaklaşım önerilmiştir. Bu yaklaşımda öncelikle rüzgâr hız verileri skalogram görüntülere dönüştürülmesi ve ardından bu görüntüler önerilen model CNN modelinden transfer öğrenimine dayalı olarak öznetelik çıkarımı yapılarak rüzgâr hız tahmini yapılmıştır.

Deneysel sonuçlara dayanarak, önerilen modelinin daha kısa tahmin dönemleri için üstün tahmin performansı sergilediği görülmektedir. Spesifik olarak, 3 saatlik ileri tahminlerde RMSE, R ve MAE değerlerinin sırasıyla 0,0961, 0,6612 ve 0,0745 performans değerlerine sahiptir. 2 saatlik ileri tahminler, RMSE, R ve MAE değerlerinin 0,0804, 0,7397 ve 0,0590 olmasıyla performansın biraz arttığı görülmektedir. 1 saatlik ileri tahminler için model sırasıyla 0,0615, 0,8757 ve 0,0448 RMSE, MAE ve R değerlerine ulaşarak performansının daha da arttığı ve yüksek düzeyde doğruluk ve güvenilirliğe sahip olduğu gözlemlenmektedir.

Deneysel sonuçlar, 1 saatlik ileri tahminin en etkili tahmin olduğunu ve bu tahminin güvenilir ve doğru rüzgâr hızı tahminleri elde etmek için sağlam bir araç olduğunu gösteriyor. Benzer şekilde gerçek ve normalize edilmiş hız tahmin grafikleri de bu sonucu desteklemektedir. 1 saatlik ileri tahmin için gerçek ve normalleştirilmiş sonuçların gözlemlenen verilerle yakından uyumlu olduğunu göstererek modelin kısa vadeli rüzgâr hızı tahminindeki etkinliğini güçlendirmektedir.

Araştırmacılar gelecekteki çalışmalarda, kısa vadeli rüzgâr hız tahmin doğruluğunu daha da artırmak için zamana bağlı rüzgâr hız verilerinin farklı yaklaşımları ile görüntüye dönüştürerek ESA modelleri üzerindeki etkileri araştırılacaktır.

KAYNAKLAR

- [1] Yoon SH, Kim SY, Parkı GH, Kim YK, Cho CH, and Park BH Multiple power-based building energy management system for efficient management of building energy. *Sustainable Citiesand Society*. 2018; 42: 462–470.
- [2] Tseng ML, Ardaniah V, Sujanto RY, Fujii M, and Lim MK, Multicriteria assessment of renewable energy sources under uncertainty: Barriers to adoption. *Technological Forecasting and Social Change*. 2021; 171: 120937.
- [3] Zhang J, Cheng C, and Yu S, Recognizing the mapping relationship between wind power output and meteorological information at a province level by coupling GIS and CNN technologies. *Applied. Energy*. 2024; 360: 122791.
- [4] Lin J, Yang X, Niu S, Yu H, Zhong J, and Jian L, Inflatable Savonius wind turbine with rapid deployment and retrieval capability: Structure design and performance investigation. *Energy Conversion and Management*. 2024; 310: 118480.
- [5] Li Y, Wang P, Wu Z, and Su Y, Collaborative monitoring of wind turbine performance based on probabilistic power curve comparison. *Renewable Energy*.2024; 231: 120919.
- [6] Li Q, Wang G, Wu X, Gao Z, and Dan B, Arctic short-term wind speed forecasting based on CNN-LSTM model with CEEMDAN. *Energy*.2024; 299: 131448.
- [7] Chen G and Lombardo FT, An automated classification method of thunderstorm and non-thunderstorm wind data based on a convolutional neural network. *Journal of Wind Engineering and Industrial Aerodynamics*. 2020; 207: 104407.
- [8] Özsoy MF, Aydoğan H, Türkiye’de Rüzgâr Enerjisi Kurulu Gücün Yapay Sınır Ağı ile Tahmini. 2017.
- [9] Harbola S and Coors V, One dimensional convolutional neural network architectures for wind prediction, *Energy Conversion. Management*. 2019; 195: 70–75.
- [10] Gan Z, Li C, Zhou J, and Tang G, Temporal convolutional networks interval prediction model for wind speed forecasting. *Electric Power Systems Research*. 2021; 191: 106865.

- [11] Sergio AT and Ludermir TB, Deep Learning for Wind Speed Forecasting in Northeastern Region of Brazil. 2015 Brazilian Conference on Intelligent System. 2015; 322–327.
- [12] Duan J, Zuo H, Bai Y, Duan J, Chang M, and Chen B, Short-term wind speed forecasting using recurrent neural networks with error correction. *Energy*. 2021; 217: 119397.
- [13] Hong YY and Satriani TRA, Day-ahead spatiotemporal wind speed forecasting using robust design-based deep learning neural network. *Energy*. 2020; 209: 118441.
- [14] Mehrkanoon S, Deep shared representation learning for weather elements forecasting. *Knowledge-Based System*. 2019; 179: 120–128.
- [15] Ma Z, Chen H, Wang et al J, Application of hybrid model based on double decomposition, error correction and deep learning in short-term wind speed prediction, *Energy Conversion and Management*. 2020; 205: 112345.
- [16] Chandran V, Patil C, Merline Manahoran A Wind power forecasting based on time series model using deep machine learning algorithms. *Materials Today Proceedings*. 2021; 47: 115–126.
- [17] Hong YY and Rioflorido CLPP, A hybrid deep learning-based neural network for 24-h ahead wind power forecasting, *Appl. Energy*. 2019; 250: 530–539.
- [18] Zhou M, Wang B, Guo S, and Watada J, Multi-objective prediction intervals for wind power forecast based on deep neural networks. *Information. Sciences*. 2021; 550: 207–220.
- [19] Peng X, Wang H, Lang J, Li W, Xu Q, Zhang Z, Cai T, Duan S, Liu F, Li C, EALSTM-QR: Interval wind-power prediction model based on numerical weather prediction and deep learning. *Energy*. 2021; 220: 119692.
- [20] <http://www.enerjibes.com/enerji/>.
- [21] Acikgoz H, Budak U, Korkmaz D, Yildiz C, WSFNet: An efficient wind speed forecasting model using channel attention-based densely connected convolutional neural network. *Energy*. 2021; 233: 121121.
- [22] Breeze P, Wind Power. *Power Generation Technologies*. 2019: 251–273.

- [23] <https://www.elektrikport.com/makale-detay/ruzgar-enerjisinin-gelisimi-ve-tarihi/4309#ad-image-0>.
- [24] Durak M, Özer S, Rüzgar enerjisi teori ve uygulama. 2008.
- [25] <https://www.enerjiportali.com/ruzgar-enerjisi-nedir/>.
- [26] Kaplan YA, Overview of wind energy in the world and assessment of current wind energy policies in Turkey. *Renewable Sustainable Energy Reviews*. 2015; 43: 562–568.
- [27] <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-ruzgar>.
- [28] <https://www.enerjiatlasi.com/ruzgar-enerjisi-haritasi/turkiye>
- [29] Global Wind Report 2021 Dünya Enerji Konseyi Türkiye 2021 Küresel Rüzgar Raporu. 2021.
- [30] Li C, Zhu Z, Yang H, and Li R, An innovative hybrid system for wind speed forecasting based on fuzzy preprocessing scheme and multi-objective optimization. *Energy*. 2019; 174: 1219–1237.
- [31] Foley AM, Leahy PG, Marvuglia A and McKeogh EJ, Current methods and advances in forecasting of wind power generation. *Renewable Energy*. 2012; 37: 1–8.
- [32] Yoldaş İS, Bingöl F, Rüzgar Enerjileri İçin Atmosferik Modeller İle Kısa Süreli Tahmin Yöntemlerinin İncelenmesi. 6. İzmir Rüzgâr Sempozyumu, 2021.
- [33] Liu H, Yu C, Wu H, Duan Z and Yan G, A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting. *Energy*. 2020; 202: 117794. .
- [34] Ramasamy P, Chandel SS and Yadav AK, Wind speed prediction in the mountainous region of India using an artificial neural network model. *Renewable Energy*. 2015; 80: 338–347.
- [35] Li LL, Zhao X, Tseng ML and Tan RR, Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm. *Journal of. Cleaner Production*. 2020; 242: 118447.
- [36] Zendehboudi A, Baseer MA and Saidur R, Application of support vector machine models for forecasting solar and wind energy resources: A review. *Journal Cleaner Production*. 2018; 199: 272–285.

- [37] Janarthanan R, Balamurali R, Annapoorani A and Vimala V. Prediction of rainfall using fuzzy logic. *Materials Today Proceedings*. 2021; 37: 959–963.
- [38] Mohandes M, Rehman S and Rahman SM, Estimation of wind speed profile using adaptive neuro-fuzzy inference system (ANFIS). *Applied Energy*.2011; 88: 4024–4032.
- [39] Van Assen M, Lee SJ and De Cecco CN, Artificial intelligence from A to Z: From neural network to legal framework. *Euroean Journal Radiology*. 2020; 129: 109083.
- [40] Subasi A, Machine learning techniques, in *Practical Machine Learning for Data Analysis Using Python*. Elsevier. 2020; 91–202.
- [41] Ataseven B, Yapay Sinir Ağları İle Öngörü Modellemesi. *Dergipark*. 2013; 101–115.
- [42] Kırbaş İ, İstatistiksel Metotlar ve Yapay Sinir Ağları Kullanarak Kısa Dönem Çok Adımlı Rüzgâr Hızı Tahmini, *SAÜ Fen Bilimleri Enstitüsü Dergisi*. 2018; 1–1.
- [43] Yavuz S, Deveci M, İstatistiksel Normalizasyon Tkniklerinin Yapay Sinir Ağın Performansına Etkisi. *Dergipark*. 2012; 167–187.
- [44] Arı A, Berberler ME, Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. *Dergipark*. 2017; 55–73.
- [45] Dildade A, İres İ, Ali M, Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformör Sargısının Termal Analizi. *Dergipark*.2011; 905–913.
- [46] Djordjevic IB, Quantum machine learning, in *Quantum Communication, Quantum Networks, and Quantum Sensing*. Elsevier. 2023; 491–561.
- [47] Öztür K, Ergin M, Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Dergipark*. 2018; 25–36.
- [48] Nakaura T, Higaki T, Awai K, Ikeda O and Yamashita Y, A primer for understanding radiology articles about machine learning and deep learning, *Diagnostic Interventional Imaging*. 2020; 101: 765–770.
- [49] Erdoğan P, Evrişimli Sinir Ağlar, 2020.
- [50] Li K, Xi Y, Su Z, Zhu J and Wang B, Research on reservoir lithology prediction method based on convolutional recurrent neural network. *Computers Electrical Engineering*. 2021; 95: 107404.

- [51] Memon N, Parikh H, Patel SB, Patel D and Patel VD, Automatic land cover classification of multi-resolution dualpol data using convolutional neural network (CNN). *Remote Sensing Applications Society Environment*. 2021; 22: 100491.
- [52] Raval D and Undavia JN, A Comprehensive assessment of Convolutional Neural Networks for skin and oral cancer detection using medical images. *Healthcare Analytics*. 2023; 3: 100199.
- [53] Fotouhi S, Pashmforoush F, Bodaghi M and Fotouhi M, Autonomous damage recognition in visual inspection of laminated composite structures using deep learning. *Composite Structures*. 2021; 268: 113960.
- [54] Zhou X, Yu T, Wang G, Tool wear classification based on convolutional neural network and time series images during high precision turning of copper. *Wear*. 2023; 522: 204692.
- [55] Li B, Hearing loss classification via AlexNet and extreme learning machine. *International Journal of Cognitive Computing Engineering*. 2021; 2: 144–153.
- [56] Yang L, Yu X, Zhang S, GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases. *Computers and Electronics Agriculture*. 2023; 204: 107543.
- [57] Wang S and Feng Z, Multi-sensor fusion rolling bearing intelligent fault diagnosis based on VMD and ultra-lightweight GoogLeNet in industrial environments. *Digital Signal Processing*. 2024; 145: 104306.
- [58] Chen SH, Wu YL, Pan CY, Lian LY and Su QC, Breast ultrasound image classification and physiological assessment based on GoogLeNet. *Journal of Radiation Research Applied Sciences*. 2023; 16: 100628.
- [59] Liu X and Aldrich C, Froth image based monitoring of platinum group metals flotation with vision transformers and convolutional neural networks. *Minerals Engineering*. 2024; 215: 108790.
- [60] Berlin Shaheema Suganya DK and Muppalaneni NB, Explainability based Panoptic brain tumor segmentation using a hybrid PA-NET with GCNN-ResNet50. *Biomedical Signal Processing Control*. 2024; 94: 106334.
- [61] Ben Nasr Barber F and Elloumi Oueslati A, Human exons and introns classification using pre-trained Resnet-50 and GoogleNet models and 13-layers CNN model. *Journal Genetic Engineering and Biotechnology*. 2024; 22: 100359.

- [62] Nijaguna GS, Babu JA, B, Parameshachari BD, R. Prado PR and Frnda J, Quantum Fruit Fly algorithm and ResNet50-VGG16 for medical diagnosis. *Applied Soft Computing*. 2023; 136: 110055.
- [63] Wang Z, Zhao Y and Kong D, Application of 3D fluorescence spectroscopy and a convolutional neural network for oil emulsion species identification, *Measurement* 2024; 237: 115177.
- [64] Tekler ZD, Lei Y and Chong A, Data-efficient Comfort Modeling: Active Transfer Learning for Predicting Personal Thermal Comfort using Limited Data, *Energy Buildings*. 2024; 114507.
- [65] Karki S, Basak J, Tamrakar N, Strawberry disease detection using transfer learning of deep convolutional neural networks. *Scientia Horticulturae*. 2024; 332: 113241.
- [66] Xiao M, Vellayappan K, Gudena K, and Z. Wu, Optimization-based multi-source transfer learning for modeling of nonlinear processes. *Chemical Engineering Science*. 2024; 295: 120117.
- [67] Sadowsky J, Investigation of Signal Characteristics Using the Continuous Wavelet Transform. 1996.
- [68] Biswas A. and Si BC, Application of Continuous Wavelet Transform in Examining Soil Spatial Variation: A Review. *Mathematical Geosciences*. 2011; 43: 379–396.
- [69] https://www.weisang.com/en/documentation/timefreqspectralalgorithmcwt_en/.
- [70] Shahsenov I, Malikov R, Cook P, Grant S, Ismayilov N and Abbasov K, Prediction of Gamma Ray data from pre-stack seismic reflection partial angle stacks using Continuous Wavelet Transform and convolutional neural network approach. *Journal Applied Geophysics*. 2022; 197: 104523.