

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**TÜRKİYE’NİN GÜNLÜK RÜZGAR ENERJİSİ ÜRETİMİNİN DERİN
ÖĞRENME İLE MODELLENMESİ**

Çağatay TEKİNAY

İSTATİSTİK ANABİLİM DALI

**ANKARA
2022**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

TÜRKİYE’NİN GÜNLÜK RÜZGAR ENERJİSİ ÜRETİMİNİN DERİN ÖĞRENME İLE MODELLENMESİ

Çağatay TEKİNAY

Ankara Üniveristesi
Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı

Danışman: Doç. Dr. Rukiye DAĞALP

Eş Danışman: Dr. Öğr. Üyesi Kamil Demirberk ÜNLÜ

Sanayi ve teknolojiadaki gelişmeler ile birlikte elektriğe olan talep gün geçtikçe artmaktadır. Elektriğin depolanamaması nedeniyle üretim ve tüketim dengesini sağlayabilmek büyük önem arz etmektedir. Bu dengenin korunabilmesi ve doğru politikaların uygulanabilmesi için güçlü bir öngörüye ihtiyaç duyulmaktadır. Güçlü bir öngörüye sahip olabilmek için ise yeterli bilgiye sahip bir veri setine ve istatistiksel modellere ihtiyaç vardır. Bu çalışmada 1 Ocak 2015 tarihinden 23 Ocak 2022 tarihine kadarki TEİAŞ tarafından oluşturulmuş günlük bazda rüzgar enerjisi sayesinde üretilen elektrik yükü miktarını içeren veri seti üzerinde çalışılmıştır. Çalışmanın amacı; Türkiye’deki günlük rüzgar enerjisinden üretilen elektriğin derin öğrenme teknikleri kullanılarak tahmin modelinin oluşturulması ve gerçek değerlere yakın tahmin değerleri üretebilmektir. Derin öğrenme teknikleri birçok tahmin probleminin çözümünde etkili sonuçlar vermektedir ve derin öğrenmenin popülaritesi tüm dünyada hızla artmaktadır. Bu çalışmada ise etkili bir tahmin modeli kurabilmek için Uzun- Kısa Vadeli Bellek (LSTM), İki Yönlü Uzun- Kısa Vadeli Bellek (BLSTM), Kapılı Tekrarlayan Ağ (GRU) ve Evrişimli Sinir Ağı (CNN) algoritmaları kullanılmış ve karşılaştırılmıştır. Algoritmalar çalıştırılırken en iyi performansı tespit etmek için gecikme boyutu (lag size) ve düğüm sayısı (number of nodes) çeşitli kombinasyonlarda test edilmiştir. Önerilen dört algoritmanın performansını değerlendirebilmek için Belirleme Katsayısı (R^2), Hata Kare Ortalaması (MSE), Hata Kareler Ortalamasının Karekökü (RMSE) ve Hatanın Mutlak Ortalaması (MAE) kullanılmıştır. Test setindeki tahmin sonuçları performans metrikleri üzerinden değerlendirildiğinde CNN algoritmasının en iyi performansı gösteren algoritma olduğuna karar verilmiştir. CNN algoritmasının en iyi tahmin değeri $MAE = 0.0063$, $MSE = 0.0001$, $RMSE = 0.0083$, $R^2 = 0.9986$ olarak hesaplanmıştır.

Ağustos 2022, 81 sayfa

Anahtar Kelimeler: Derin öğrenme; tahmin; istatistiksel modelleme; elektrik üretimi; rüzgar enerjisi

ABSTRACT

Master Thesis

MODELING DAILY WIND POWER PRODUCTION OF TURKEY USING DEEP LEARNING

Çağatay TEKİNAY

Ankara University
Graduate School of Natural and Applied Sciences
Department of Statistics

Supervisor: Assoc. Prof. Dr. Rukiye DAĞALP

Co-Supervisor: Assist. Prof. Dr. Kamil Demirberk ÜNLÜ

The increasing world population and the technological and industrial advancements result in an ever-growing demand for electricity. Maintaining the balance between production and consumption requires adopting new policies and using reliable predictive techniques in the absence of efficient and cost-effective methods to store electricity. Deep learning methods have been used to support various decision-making processes by assessing and analyzing big data and providing accurate predictions. As such, deep learning models can be utilized to improve our ability to predict the energy production in many different parts of the world. In this thesis, we are particularly interested in establishing a forecasting model of Turkey's daily wind energy production using deep learning methods based on the data between January 1, 2015, to January 23, 2022. To achieve that, we apply Long-Short-Term Memory (LSTM), Bidirectional Long-Short-Term Memory (BLSTM), Gated Repetitive Network (GRU), and Convolutional Neural Network (CNN). Long-Short-Term Memory (LSTM), Bidirectional Long-Short-Term Memory (BLSTM), Gated Repetitive Network (GRU), and Convolutional Neural Network (CNN) using different lag sizes and number of nodes. We evaluate the predictive results of these algorithms by calculating performance metrics such as Adjusted R squared, Mean Squared Error (MSE), Root Squared Mean Squared Error (RMSE) and Absolute Mean Error (MAE). Our results show that CNN algorithm has the best predictive value with MAE = 0.0063, MSE = 0.0001, RMSE= 0.0083, $R^2= 0.9986$.

August 2022, 81 pages

Key Words: Deep learning; forecasting; statistical modelling; electricity production; wind energy

TEŞEKKÜR

Yüksek Lisans eğitimime başladığım ilk günden itibaren desteğini hep yanımda hissettiğim, hiç tükenmeyen sabrı, yardımseverliği ve çok kıymetli emeklerinden dolayı danışman hocam Sayın Doç. Dr. Rukiye DAĞALP'e (Ankara Üniversitesi İstatistik Anabilim Dalı) ve tez çalışmalarımın her aşamasında bana destek veren, beni cesaretlendiren, bilgisini ve ilgisini hiç esirgemeyen eş danışmanım Sayın Dr. Öğr. Üyesi Kamil Demirberk ÜNLÜ'ye (Atılım Üniversitesi Endüstri Mühendisliği Anabilim Dalı) en içten duygularıyla teşekkür eder, saygılarımı sunarım.

Yüksek lisans tez savunmama jüri olarak katılan Prof. Dr. Yılmaz AKDİ ve Dr. Öğr. Üyesi Şahika GÖKMEN'e katkılarından dolayı teşekkür ederim.

En büyük gurur kaynağım, canımdan çok sevdiğim kardeşim, abim Çağrı TEKİNAY'a sadece mükemmel bir kardeş oldu için değil, aynı zamanda en büyük ilham kaynağım olduğu için sonsuz teşekkür ederim.

Üzerimdeki emekleri tarif edilemez büyüklükte olan ve hayatımın her anında, tükenmeyen sevgileri ile yanımda olan, canım annem Zahide TEKİNAY'a ve canım babam Katip TEKİNAY'a büyük bir gururla teşekkür ederim.

Sevgisini ve desteğini tanıdığım günden beri en derinden hissettiğim ve varlığıyla bana güç veren Ecehan BAYRAMOĞLU'na çok teşekkür ederim.

Çağatay TEKİNAY
Ankara, Ağustos 2022

İÇİNDEKİLER

TEZ ONAYI

ETİK.....	i
ÖZET.....	ii
TEŞEKKÜR.....	iv
SİMGELER VE DİZİNİ.....	vii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ.....	xii
1. GİRİŞ.....	1
1.1 Türkiye’de Elektrik Enerjisi Üretimi.....	1
1.2 Rüzgar Gücü Nedir ?.....	5
1.3 Rüzgar Enerjisinin Tarihi ve Gelişimi.....	9
1.4 Türkiye’de Rüzgar Enerjisinin Tarihçesi ve Kullanımı.....	10
1.5 Rüzgar Enerjisi Tahmin Yöntemleri.....	11
1.5.1 Rüzgar enerjisi tahmin yöntemlerinin farklı zaman dilimlerine sınıflandırılması.....	12
1.5.2 Rüzgar rnerjisi tahmin modellerinin sınıflandırılması.....	13
1.5.2.1 Süreklilik yöntemi.....	13
1.5.2.2 Fiziksel yöntemler.....	13
1.5.2.3 İstatistiksel yöntemler.....	14
1.5.2.4 Hibrit yöntemler.....	15
1.5.2.5 Mekansal korelasyon yöntemleri.....	15
1.5.2.6 Yapay zeka yöntemleri.....	15
2. LİTERATÜR TARAMASI.....	17
3. TEZİN AMACI, ÖNEMİ VE YÖNTEMİ.....	21
4. YAPAY SİNİR AĞLARI.....	23
4.1 İnsan Beyni ve Yapay Sinir Ağları Arasındaki İlişki.....	30
4.2 Tekrarlı Yapay Sinir Ağları (Recurrant Neural Network).....	31
4.2.1 Tekrarlı yapay sinir ağları tipleri.....	37
4.2.2 Uzun kısa süreli bellek (Istm).....	41

4.2.3 İki yönlü uzun kısa süreli bellek (blstm)	44
4.2.4 Evrişimli sinir ağları	44
4.2.4.1 Evrişimsel sinir ağında aktivasyon fonksiyonu kullanımı	49
5. TÜRLERİNE GÖRE AKTİVASTON FONKSİYONLARI.....	51
5.1 Basamak(Step) Fonksiyonu	51
5.2 Doğrusal(Linear) Fonksiyon	51
5.3 Sigmoid Fonksiyonu	52
5.4 Hiperbolik Tanjant Fonksiyonu	53
5.5 Düzeltmiş Doğrusal Birim(Rectifier Linear Unit)	54
6. TÜRLERİNE GÖRE OPTİMİZASYON FONKSİYONLARI VE KAYIP FONKSİYONU.....	56
6.1 Kayıp Fonksiyonu (Loss Function).....	56
6.2 Gradyan İniş (Gradient Descent)	56
6.2.1 Toplu gradyan iniş (batch gradient descent).....	57
6.2.2 Stokastik gradyan iniş (Stochastic gradient descent).....	57
6.3 Momentum Yöntemi	57
6.4 AdaGrad Yöntemi.....	58
6.5 RMSprop Yöntemi.....	58
6.6 AdaDelta Yöntemi.....	58
6.7 Adam Fonksiyonu (Adam Function).....	58
7. VERİ SETİ VE VERİ ANALİZİ.....	59
8. SONUÇ VE ÖNERİLER	75
KAYNAKÇA.....	78
ÖZGEÇMİŞ	81

SİMGELER DİZİNİ

*	Bileşen bazında çarpma işlemini
\bar{y}	Gözlenen veri ortalaması
\hat{f}_i	Tahmini çıktı değeri
\otimes	Eleman bazında matris çarpımı
c_{t-1}	Son bellek hücresi
X_{\min}	Veri setindeki en düşük değer
X_{\max}	Veri setindeki en yüksek değer
Σ	Toplam Sembolü
C_t	Bellek hücresinin t zamanına kadar olan bilgileri
f_t	Giriş kapısı
h	Gizli birimin konumunu temsil eden indeks
i_t	Unutma kapısı
j	Giriş birimi temsil eden indeks
m/s	Metre/Saniye
o_t	Çıkış kapısı
R^2	Belirleme Katsayısı
SS_{res}	Artık Kareler Toplamı
SS_{tot}	Toplam Kare Toplamı
v_{ih}	h' inci gizli birimden i' inci çıkışa çıkış ağırlığı
W_0	Her gizli katmanı besleyen özel ağırlık
W_j	Ağırlık
X_0	Özel girdi değeri
X_i	Girdi değeri
y_i	Gözlenen veri
Z_0	Çıktı katmanını besleyen özel ağırlık
σ	Sigmoid Fonksiyonu

Kısaltmalar

AdaDelta	An Adaptive Learning Rate Method
AdaGrad	Adaptive Gradient Algorithm
Adam	Adaptive Moment Estimation
ANN	Artificial Neural Network
AR	Auto Regressive Model
ARIMA	Auto-Regressive Integrated Moving Average Model
ARMA	Auto Regressive Moving Average Model
BLSTM	Bidirectional Long Short-Term Memory
CNN	Convolutional Neural Networks
FFNN	Feed Forward Neural Network
GPU	Graphics Processing Unit
GRU	Gated Reccurant Unit
GW	Gigawatt
GWh	Gigawatt hours
İZKA	İzmir Kalkınma Ajansı
km	Kilometre
kW	Kilowatt
LR	Linear Regression
LSTM	Long Short-Term Memory
MA	Moving Average Model
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MARS	Multivariate Adaptive Regression Spline
MSE	Mean Square Error
MW	Megawatt
ReLU	Rectified Linear Unit
RMSE	Root Mean Square Error
RMSprop	Root Mean Squared Propagation
RNN	Reccurant Neural Network
SARIMA	Seasonal Auto Regressive Integrated Moving Average
SCADA	Supervisory Control And Data Acquisition
TEİAŞ	Türkiye Elektrik İletim A.Ş.
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 1.1 Türkiye’de kurulu enerji üretim tesislerinin megavat cinsinden yıllara göre üretim miktarları	3
Şekil 1.2 Türkiye’de 2010 ve 2020 yılları için birincil enerji kaynaklarına göre kurulu güç miktarları.....	4
Şekil 1.3 Türkiye’de 2020 yılı için birincil enerji kaynaklarının dağılımı	5
Şekil 1.4 Kanat sayılarına göre rüzgar türbini modelleri	6
Şekil 1.5 İzmir’in batısında yer alan Sığacık rüzgar türbinleri	8
Şekil 1.6 Rüzgarın geliş yönüne göre rüzgar türbini modelleri.....	9
Şekil 4.1 Nöronun yapısı.....	23
Şekil 4.2 Nöronun anatomisi	24
Şekil 4.3 Eğitilmiş modellerin performans ölçümlerinin karşılaştırılması	25
Şekil 4.4 Eğitilmiş modellerin performans ölçümlerinin karşılaştırılması	28
Şekil 4.5 Perceptron Modeli.....	28
Şekil 4.6 İnsan beyni.....	30
Şekil 4.7 Gizli katmanlar boyunca ağırlığın “1” den küçük olması durumunda ilk adımdaki girdinin son adımdaki çıktı üzerinde etkisinin hızla azaldığını yeşil rengin açılan renk tonları ile gösteren bir kaybolan gradyan problemi... 33	33
Şekil 4.8 Çok katmanlı yapay sinir ağının Tekrarlı yapay sinir ağına dönüşmeden önceki hali	34
Şekil 4.9 Çok katmanlı yapay sinir ağının tek katman halinde gösterimi.....	34
Şekil 4.10 Vektör gösterimi.....	35
Şekil 4.11 Dikey vektör gösterimi	35
Şekil 4.12 En basit haliyle Tekrarlayan Yapay Sinir ağı gösterimi.....	36
Şekil 4.13 Tekrarlayan Yapay Sinir ağı gösterimi.....	37
Şekil 4.14 Tekten teke (one-to-one) tekrarlayan yapay sinir ağı gösterimi	38
Şekil 4.15 Tekten yığına (one-to-many) tekrarlayan yapay sinir ağı gösterimi	38
Şekil 4.16 Yığından teke (many-to-one) tekrarlayan yapay sinir ağı gösterimi	39
Şekil 4.17 Eşit birim boyutuna sahip yığından yığına tekrarlayan yapay sinir ağı gösterimi.....	40
Şekil 4.18 Eşit birim boyutuna sahip olmayan yığından yığına tekrarlayan yapay sinir ağı gösterimi	40
Şekil 4.19 Uzun Kısa Süreli Bellek (LSTM) gösterimi	41
Şekil 4.20 Kapılı Tekrarlayan Birim gösterimi	43
Şekil 4.21 Evrişimli Yapay Sinir Ağı gösterimi.....	44

Şekil 4.22 Gülümseme ifadesinin dedektör matrisi gösterimi	45
Şekil 4.23 Giriş görüntüsü matrisi ve özellik algılayıcı gösterimi	46
Şekil 4.24 Giriş görüntüsü matrisi ve özellik algılayıcının eleman-eleman çarpımı.....	47
Şekil 4.25 Fotoğraf görüntüsünü keskinleştiren filtre ve filtreye ait özellik haritası gösterimi.....	48
Şekil 4.26 Fotoğraf görüntüsünde kenar algılayıcı filtre uygulaması ve filtreye ait özellik haritası gösterimi	48
Şekil 4.27 Fotoğraf görüntüsünü keskinleştiren filtre ve filtreye ait özellik haritası gösterimi.....	49
Şekil 5.1 Basamak Fonksiyonu	51
Şekil 5.2 Doğrusal Fonksiyon	52
Şekil 5.3 Sigmoid Fonksiyonu	53
Şekil 5.4 Hiperbolik Tanjant Fonksiyonu	54
Şekil 5.5 Düzeltilmiş Doğrusal Birim (Relu) Fonksiyonu.....	55
Şekil 7.1 Veri Setine uygulanan karar aşamaları.....	60
Şekil 7.2 LSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki.....	64
Şekil 7.3 LSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki.....	65
Şekil 7.4 BLSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki	67
Şekil 7.5 BLSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki	68
Şekil 7.6 CNN modelinin gerçek değer ve tahmin değerleri arasındaki ilişki.....	72
Şekil 7.7 CNN modelinin gerçek değer ve tahmin değerleri arasındaki ilişki.....	73
ÖZET	i

ÇİZELGELER DİZİNİ

Çizelge 1.1 Türkiye’de yıllara ve enerji kaynaklarına göre enerji üretim miktarları	2
Çizelge 7.1 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre LSTM algoritması ile hesaplanan performans metrikleri	63
Çizelge 7.2 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre BLSTM algoritması ile hesaplanan performans metrikleri	66
Çizelge 7.3 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre GRU algoritması ile hesaplanan performans metrikleri	69
Çizelge 7.4 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre CNN algoritması ile hesaplanan performans metrikleri	70
Çizelge 7.5 Algoritmaların performans metrikleri üzerinden karşılaştırılması.....	74

1. GİRİŞ

Teknolojinin gelişmesi ve artan dünya nüfusuna paralel olarak artan enerji ihtiyacı nedeniyle yenilenebilir enerji kaynakları her geçen gün daha fazla önem kazanmaktadır. Yenilenebilir enerji kaynaklarının en önemli özelliği sadece ucuz olması değil, aynı zamanda çevre dostu olmasıdır. Diğer elektrik enerjisi üreten yöntemler ya hava kirliliğine sebep olan karbon bazlı kaynakları kullanmaktadır, ya da geri dönüşü olmayan durumlara yol açabilen nükleer enerji kaynaklarıdır. Küresel ısınmaya sebep olan enerji üretim yöntemleri yerine, sürdürülebilir temiz bir çevre politikası izlemek için, yenilenebilir enerji kaynakları gereklilik olmaktan çıkarak zorunluluk derecesine yaklaşmaktadır. Karbon bazlı kaynakların tükeniyor olmasından dolayı, alternatif yeşil enerji kaynaklarının önemi artmaktadır. Güneş, rüzgar, jeotermal, hidroelektrik ve biokütle yenilenebilir enerji kaynaklarından bazılarıdır. Rüzgar enerjisi, onlarca yıldır birçok gelişmiş ülkede elektrik enerjisi üretimi için kullanılmakta olup, kurulu güç kapasiteleri olarak enerji üretiminde başı çektiği bilinmektedir.

1.1 Türkiye’de Elektrik Enerjisi Üretimi

T.C. Enerji ve Tabii Kaynaklar Bakanlığı raporuna göre 2021 yılında Türkiye’nin elektrik üretiminin %31.4’ü kömürden, %32.7’si doğal gazdan, %16.8’i hidrolik enerjiden, %9.4’ü rüzgar enerjisinden, %4’ü güneş enerjisinden, %3.2’si jeotermal enerjiden ve %2.4’ü diğer enerji kaynaklarından elde edilmiştir. Bu doğrultuda, 2022 Mayıs ayı sonu verilerine göre Türkiye’nin kurulu gücü 100.667 MW(megavat) olarak hesaplanmıştır. Son durumda ise, 2022 yılının Mayıs ayı sonu itibariyle Türkiye’nin kurulu gücünün kaynaklara göre dağılımı; %31,3’ü hidrolik enerji, %25,1’i doğal gaz, %20,3’ü kömür, %10,9’u rüzgâr enerjisi, %8,3’ü güneş enerjisi, %1,7’si jeotermal enerji ve %2,4’ü ise diğer kaynaklar olarak belirlenmiştir.

Türkiye’nin elektrik enerjisi üretim santrali sayısı, 2022 yılının Mayıs ayı sonu rakamlarına göre, 10.790’a (lisanssız santraller dahil) yükselmiştir. Mevcut santrallerin ise 748 adedi hidroelektrik, 67 adedi kömür, 356 adedi rüzgâr, 63 adedi jeotermal, 346 adedi doğal gaz, 8.725 adedi güneş, 485 adedi ise diğer kaynaklı santraller olarak belirlenmiştir (Anonim 2022).

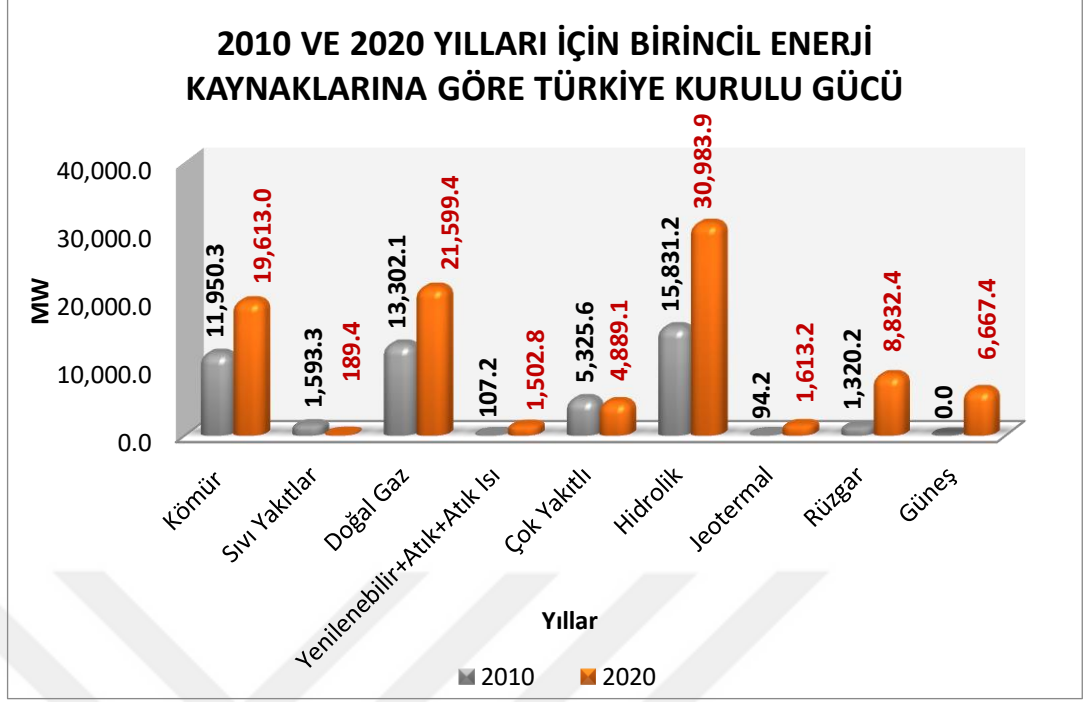
Çizelge 1.1 Türkiye’de yıllara ve enerji kaynaklarına göre enerji üretim miktarları (TEİAŞ 2020)

Yıl	Toplam (GWh)	Kömür (%)	Sıvı yakıtlar (%)	Doğal gaz (%)	Hidrolik (%)	Yenilenebilir Enerji ve Atıklar (%)
1970	8 623	%32,7	%30,2	-	%35,2	%1,9
1971	9 781	%30,4	%41,2	-	%26,7	%1,7
1972	11 242	%26,0	%43,9	-	%28,5	%1,6
1973	12 425	%26,1	%51,3	-	%21,0	%1,6
1974	13 477	%28,8	%44,8	-	%24,9	%1,5
1975	15 623	%26,3	%34,5	-	%37,8	%1,4
1976	18 283	%23,7	%29,6	-	%45,8	%0,9
1977	20 565	%23,8	%33,4	-	%41,7	%1,1
1978	21 726	%25,7	%30,7	-	%43,0	%0,6
1979	22 522	%28,6	%25,1	-	%45,7	%0,6
1980	23 275	%25,6	%25,0	-	%48,8	%0,6
1981	24 673	%24,9	%23,6	-	%51,1	%0,4
1982	26 552	%24,2	%22,4	-	%53,4	%0,0
1983	27 347	%31,4	%27,1	-	%41,5	%0,0
1984	30 614	%33,0	%23,0	-	%43,9	%0,1
1985	34 219	%43,9	%20,7	%0,2	%35,2	%0,0
1986	39 695	%49,0	%17,6	%3,4	%29,9	%0,1
1987	44 353	%39,8	%12,4	%5,7	%42,0	%0,1
1988	48 049	%26,0	%6,9	%6,7	%60,3	%0,1
1989	52 043	%38,9	%8,2	%18,3	%34,5	%0,1
1990	57 543	%35,1	%6,8	%17,7	%40,2	%0,2
1991	60 246	%35,8	%5,6	%20,8	%37,6	%0,2
1992	67 342	%36,5	%7,8	%16,0	%39,5	%0,2
1993	73 808	%32,1	%7,0	%14,6	%46,1	%0,2
1994	78 322	%36,0	%7,1	%17,6	%39,1	%0,2
1995	86 247	%32,5	%6,7	%19,2	%41,2	%0,4
1996	94 862	%32,0	%6,9	%18,1	%42,7	%0,3
1997	103 296	%32,8	%6,9	%21,4	%38,5	%0,4
1998	111 022	%32,2	%7,2	%22,4	%38,0	%0,3
1999	116 440	%31,8	%6,9	%31,2	%29,8	%0,3
2000	124 922	%30,6	%7,5	%37,0	%24,7	%0,3
2001	122 725	%31,3	%8,4	%40,4	%19,6	%0,3
2002	129 400	%24,8	%8,3	%40,6	%26,0	%0,3
2003	140 581	%22,9	%6,6	%45,2	%25,1	%0,2
2004	150 698	%22,8	%5,0	%41,3	%30,6	%0,3
2005	161 956	%26,6	%3,4	%45,3	%24,4	%0,3
2006	176 300	%26,4	%2,4	%45,8	%25,1	%0,3
2007	191 558	%27,9	%3,4	%49,6	%18,7	%0,4
2008	198 418	%29,1	%3,8	%49,7	%16,8	%0,6
2009	194 813	%28,6	%2,5	%49,3	%18,5	%1,2
2010	211 208	%26,1	%1,0	%46,5	%24,5	%1,9
2011	229 395	%28,8	%0,4	%45,4	%22,8	%2,6
2012	239 497	%28,4	%0,7	%43,6	%24,2	%3,1
2013	240 154	%26,6	%0,7	%43,8	%24,7	%4,2
2014	251 963	%30,2	%0,9	%47,9	%16,1	%4,9
2015	261 783	%29,1	%0,9	%37,9	%25,6	%6,5
2016	274 408	%33,7	%0,7	%32,5	%24,5	%8,6
2017	297 278	%32,8	%0,4	%37,2	%19,6	%10,0
2018	304 802	%37,2	%0,1	%30,3	1%9,7	%12,7
2019	303 898	%37,1	%0,1	%18,9	%29,2	%14,7
2020	306 703	%34,5	%0,1	%23,1	%25,5	%16,8

Türkiye’de yenilenebilir enerjinin önemi ve kullanım oranları son yıllarda birçok teşvikle artmaktadır. Türkiye’de yıllara (1970-2020) ve enerji kaynaklarına göre enerji üretim miktarları Çizelge 1.1’de görülmektedir. Çizelge 1.1’e göre yenilenebilir enerji kaynaklarındaki artış 2009 yılından itibaren daha belirgin bir şekilde görülmektedir. Şekil 1.1’de Türkiye’de kurulu enerji üretim tesislerinin yıllara göre üretim miktarları, 1980 yılından 2020 yılına kadarki 40 yıllık değişimi göstermektedir. Şekil 1.2’de ise 2010 -2020 yılları arasındaki Birincil Enerji Kaynaklarına Göre Türkiye Kurulu Gücü’nü göstermektedir. Şekil 1.2’deki grafiğe göre Türkiye’de enerji üretiminde çevre dostu bir politika izlendiği söylenebilir. Aynı şekilde ayrıca Türkiye’de son 10 yılda rüzgar enerjisine yapılan yatırım da açıkça görülmektedir. Yenilenebilir enerji kaynaklarındaki kurulu gücün son 10 yıldaki artışı da yine Şekil 1.2’de gözle çarpılmaktadır.

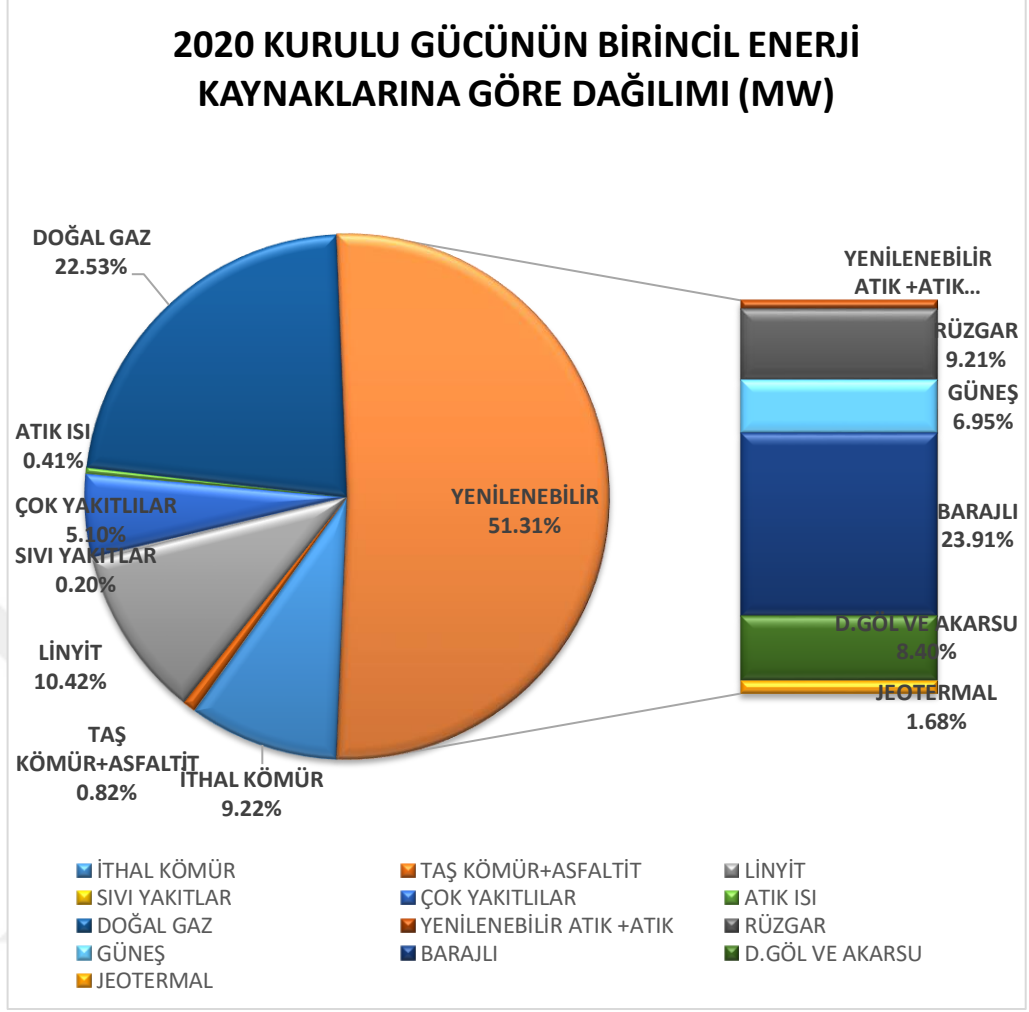


Şekil 1.1 Türkiye’de kurulu enerji üretim tesislerinin megavat cinsinden yıllara göre üretim miktarları (TEİAŞ 2020)



Şekil 1.2 Türkiye’de 2010 ve 2020 yılları için birincil enerji kaynaklarına göre kurulu güç miktarları (TEİAŞ 2020)

Şekil 1.3’de 2020 yılındaki kurulu enerji gücünün birincil enerji kaynaklarına göre dağılımı pasta grafiği ile gösterilmiştir. Grafiğe göre, Türkiye’deki enerji üretim kaynaklarının yarısının yenilenebilir enerji kaynaklarından sağlanmaya çalışıldığı ve yenilenebilir enerji kaynakları arasında kurulu gücün çoğunluğu, hidrolik enerji yöntemiyle elektrik üretilen barajlardan gelmektedir.



Şekil 1.3 Türkiye’de 2020 yılı için birincil enerji kaynaklarının dağılımı (TEİAŞ 2020)

1.2 Rüzgar Gücü Nedir ?


Rüzgar gücü ve rüzgar enerjisi kavramları, rüzgarın mekanik güç veya elektrik üretmek için kullandığı süreci tanımlar. Üretilen mekanik güç, rüzgar türbinlerini döndürür ve rüzgar enerjisi üretmeye yarar. Günümüzde şebekelere elektrik üretmek ve bu şebekeler sayesinde sanayi ve günlük yaşamda elektrik kullanmak için rüzgar enerjisinden faydalanılsa da, eski dönemlerde çiftçiler tarlalarını sulamak ve tahıllarını öğütmek için rüzgar gücünden faydalandılar. Zamanla gelişen teknoloji sayesinde rüzgar türbinlerinin de rüzgar gücünü kullanabilme ve elektrik üretme kapasiteleri artmıştır. Kurulan rüzgar çiftliklerindeki birçok rüzgar

türbini sayesinde, üretilen elektrik daha çok haneye ve sanayi kuruluşuna ulaşmıştır.

Rüzgar türbinleri, uçak kanadı veya helikopter rotor kanadı gibi çalışır ve kanatlarından gelen aerodinamik kuvveti (rüzgar gücü) kullanarak, rüzgar enerjisini elektriğe dönüştürür (Anonymous 2018a).

Fiziksel olarak bu durum, rüzgarın kanat boyunca esmesi ve kanadın bir tarafındaki hava basıncını azaltması durumudur. Rüzgar türbininin rotor kanadının iki tarafında oluşan bu basınç farkı ile hem kaldırma kuvveti hem de aerodinamik hava direnci yaratılmış olur. Kaldırma kuvveti, hava direncinden daha güçlü olduğu için rotorun dönmesine neden olur. Rotor kanat jeneratöre doğrudan veya dolaylı yoldan bağlıdır. Rüzgarın dönme hareketi ile elde ettiği kinetik enerjisi rotor sayesinde mekanik enerjiye dönüşür. Rotor mili sayesinde jeneratöre ulaştırılan devir hareketi jeneratör sayesinde elektrik enerjisine çevrilir ve aküler ile depolanarak ihtiyaca göre satışı ve dağıtımı yapılır. Bir rüzgar türbininde jeneratör, kule, hız dönüştürücüleri ve pervaneler bulunur (Elibüyük ve Üçgül 2014).

Rüzgar türbinleri, kanat sayıları, dişli özellikleri, dönme eksenleri devirleri ve ürettikleri güç potansiyellerine göre farklılıklar gösterir. Dönme eksenlerine göre, yatay, dikey ve eğik eksenli rüzgar türbinleri olarak adlandırılırlar. Kanat sayılarına göre ise tek kanatlı, iki kanatlı, üç kanatlı ve çok kanatlı olarak adlandırılırlar (Elibüyük ve Üçgül 2014).



Şekil 1.4 Kanat sayılarına göre rüzgar türbini modelleri (Durdyev 2010)

Şekil 1.4’de kanat sayılarına göre rüzgar türbinleri mevcuttur. Günümüz modern rüzgar türbinlerinde en çok kullanılan tür üç kanatlı olanıdır. En çok kullanılan rüzgar türbin çeşidinin üç kanatlı olmasının sebebi ise, rüzgar hızının tüm çeşitlerinde sabit devinimsizlik momentine sahip olmasıdır. Üç ve üçten fazla kanada sahip olan rüzgar türbinlerinde sabit devinimsizlik momentine sahip olma özelliği mevcuttur. Rüzgar türbinleri arasında en gürültülü çalışanı tek kanatlı rüzgar türbinleridir. İki kanatlı rüzgar türbinleri yaklaşık 25-30 yıl öncesi kullanılan modellerdir. İki kanatlı rüzgar türbinleri, üç kanatlı rüzgar türbinlerine göre yapısal olarak daha ekonomik görünmelerine rağmen, ek ekipman ihtiyaçlarından ötürü üç kanatlı türbinlere göre ekstra maliyetleri vardır. İki kanatlı rüzgar türbini modelleri, düşük rüzgar hızlarında, üç kanatlı türbinlere göre çok daha az miktarda devreye giren bir modeldir (Elibüyük ve Üçgül 2014).

Ülkemizde yüksek rüzgar potansiyeli olmasından ötürü, üç kanatlı rüzgar türbinlerinin kullanımı daha avantajlı olduğu için, ülkemizdeki hemen hemen tüm rüzgar santrallerinde üç kanatlı modeller tercih edilmektedir. Ülkemizde, mevcutta olan rüzgar türbinleri çoğunluğu karada yer almaktadır ve ülkemizin coğrafi özellikleri sayesinde açık deniz santraller kurulmaya müsait olsa da, henüz bu tarz sistemler yeterince gelişmiş değildir (Elibüyük ve Üçgül 2014).

İzmir Kalkınma Ajansı’nın (İZKA) son raporuna göre İzmir’in karada kurulu olan rüzgar enerjisinin yanında önemli açık deniz rüzgar enerjisi üretim fırsatlarını içerdiği belirtilmiştir. 2020 yılında yayımlanan rapora göre, Türkiye için 70 GW açık deniz rüzgar enerjisi potansiyeli olduğu belirtilmiştir. Bu sayede kurulabilecek rüzgar enerjisi santrallerinin, Türkiye ekonomisine katkısı ve istihdam yaratması açısından önemi de aynı raporda belirtilmiştir (Anonymous 2021a).



Şekil 1.5 İzmir'in batısında yer alan Sığacık rüzgar türbinleri (Anonymous 2021a)

Rüzgarı alış yönüne göre rüzgar türbinleri ikiye ayrılırlar. Şekil 1.6.'da görüldüğü üzere rüzgarı önden veya rüzgarı arkadan alan rüzgar türbinleri mevcuttur. Arkadan rüzgarı alan rüzgar türbinleri, önden rüzgarı alanlara göre daha hafif inşa edilebilir. Yıllardır yaygın olarak kullanılan model, rüzgarı önden alan modellerdir. Bu tarz modellerin ekipman ayrımlarının yanında, rüzgar türbinleri, dişli kutusu olan veya dişli kutusu olmayan rüzgar türbinleri olarak da ikiye ayrılmaktadır. Genel olarak rüzgar türbinlerinde dişli kutuları, jeneratörler ve kontrol sistemleri mevcuttur (Selin 2021).



Şekil 1.6 Rüzgarın geliş yönüne göre rüzgar türbini modelleri (Elibüyük ve Üçgül 2014)

1.3 Rüzgar Enerjisinin Tarihi ve Gelişimi

En az 3000 yıllık geçmişi olan rüzgar türbinleri su pompalamak ve daha sıklıkla tahıl öğütmek için kullanılmıştır. Yatay eksenli rüzgar türbinleri, ortaçağ avrupalısının kırsal ekonomisinin en önemli parçalarından birisiydi. Fakat fosil yakıtla çalışan sabit motorların icadı ve kırsal kesime ulaşan elektrik sayesinde eski popüleritesini yitirmiştir. (Musgrove 2010).

Rüzgar türbinlerinin yalnızca elektrik üretebilmek amacıyla ilk kullanımı, Charles Brush tarafından Amerika'da kurulan, 12 kW'lık doğru akım rüzgar türbini jeneratörüdür. 19.yy'nin sonuna kadar Charles Brush ve Danimarka'da Poul la Cour tarafından yürütülen araştırma o dönemlerdeki en önemli gelişmelerin başında gelir. 20.yy'ye gelindiğinde, 1941 yılında Amerika'da inşa edilen ve 1250 kW enerji üretebilen Smith-Putnam rüzgar türbini, önemli bir gelişme olarak kayda geçmiştir. Smith-Putnam rüzgar türbininin inşa edildiği tarihten itibaren yaklaşık 40 yıl boyunca, büyük kanat açıklığı ile birlikte, inşa edilen en büyük rüzgar türbini olma özelliğini taşımaktadır (Putnam 1948). Bu tarihten sonra çeşitli mimari tasarımlarda ve farklı teknik özelliklere sahip rüzgar türbinleri dünyanın çeşitli yerlerinde inşa edilmiştir. 1950'lerde İngiltere'de inşa edilen John Brown Engineering, Andrea Enfield, 1956'da Danimarka'da inşa edilen Gedser Machine, 1963'de Fransa'da inşa edilen Electricité de France, örnek olarak verilebilir. İnşa edilen rüzgar türbinlerine rağmen, 1973 yılında patlak veren petrol krizine kadar, rüzgar enerjisine olan talep yeterli değildi. Bu tarihten sonra rüzgar enerjisine yapılan yatırımlar artmaya başladı ve 1975 yılında, Amerika'da bir dizi prototip rüzgar türbini denemesi olmuştur (Hau 2010). İlk kez açık denizde kurulan rüzgar çiftliği, 1991 yılında Danimarka kıyısına yaklaşık 3km uzaklıkta Vindeby'de kurulan, 11450kW'lık gücüyle inşa edilen rüzgar türbinidir. 2002 yılına kadar açık denizde kurulan rüzgar türbinleri, kıyıya yakın inşa edilmiş olsa da, 2002 yılında Danimarka'nın batı kıyısının 20 km açıklarında, 160MW'lık gücüyle Horns Rev rüzgar çiftliği inşa edilmiştir. Modern rüzgar türbinlerinin evrimi ise Serrano-González ve Lacal-Arántegui'de (2016) araştırmasında anlatılmaktadır. Rüzgar enerjisinin tarihsel kullanım talebindeki değişimleri tetikleyen olaylardan bir tanesi, 1973 yılındaki petrol fiyatlarındaki aşırı yükselmedir. 1990'lardan itibaren ise bu talep, düşük karbon

salınlı enerji üretim yöntemleri olmuştur. Bu doğrultuda, 2007 yılında düzenlenen Avrupa Birliđi Enerji Politikaları, 2020 yılına kadarki süre içerisinde enerjisinin %20'sini yenilenebilir enerji kaynaklarından elde etmeyi , 2030 yılına gelindiğinde ise bu oranı %32 ye çıkarmayı planlamaktadır (Burton vd. 2021).

1.4 Türkiye’de Rüzgar Enerjisinin Tarihçesi ve Kullanımı

Türkiye, coğrafik özellikleri bakımından yenilenebilir enerji kaynakları potansiyeli yüksek olan bir ülkedir. Bu yenilenebilir enerji kaynakları potansiyelleri arasında, rüzgar enerjisi çok önemli bir yere sahiptir. Son dönemlerde, tüm dünyada olduğu gibi Türkiye’de de küresel ısınmanın etkileri fazlaca görülmektedir. Yenilenebilir enerji kaynaklarının kullanımı, enerjisinin büyük bir çoğunluğunu dışarıdan ithal eden Türkiye için, son derece önemli ve ekonomiktir. Ekonomik olmasının yanında, ülkemizdeki çevresel yapıyı bozmamak adına, son yıllarda tüm dünya da gelişen ve önemi artan rüzgar enerjisine büyük yatırımlar yapılmıştır. Yapılan yatırımlara paralel olarak, ülkemizdeki enerji kaynakları potansiyellerini ölçmek ve görselleştirmek adına “Enerji Atlası” yayınlanmıştır (Anonymous 2022a). Tüm enerji kaynakları çeşitleri bu atlas üzerinden takip edilebilmekte ve görseller sayesinde somut bir şekilde görülebilmektedir. Türkiye de elektrik üreten 36 barajın neredeyse 10 katı kadar rüzgar enerjisi potansiyeli olduğu bilinmektedir (İlkılıç 2016).

Türkiye ‘de kurulan ilk rüzgar türbini, 1986 yılında İzmir’in Çeşme ilçesi Altın Yunus Tesisleri’nde kurulmuştur. 55 kilovat elektrik üreten bu türbin, Türkiye’de kullanılan ilk rüzgar türbinidir. İlk uluslararası rüzgar türbini ise, yine Çeşme’nin Germiyan köyünde 1998 yılında kurularak elektrik üretmiştir. Türkiye’deki ilk rüzgar çiftliği, 1998 yılında Alaçatı’daki ARES adlı 12 adet rüzgar türbininden oluşan rüzgar çiftliğidir. Kayıtlı rüzgar enerjisi üreten santrallerimiz arasında kurulu güç kapasitesi olarak ilk üçte yer alan santrallerimiz arasında birincisi, 288 MW kurulu güç kapasitesi ile Manisa ilinin Soma ilçesinde yer alan Soma Rüzgar Santralidir. İkinci sırada ise, 223 MW kurulu güç kapasitesi ile İzmir’de yer alan Karaburun Rüzgar Santrali yer almaktadır. Üçüncü sırada 200 MW kurulu güç kapasitesi ile, Afyonkarahisar ilimizde bulunan Dinar Rüzgar Santrali bulunmaktadır (Anonymous 2022a).

1.5 Rüzgar Enerjisi Tahmin Yöntemleri

Sürdürülebilir enerji kaynakları karbon ayak izinde azalmayı sağlayabilir ve fosil yakıt kullanımının sınırlandırılmasında önemli bir role sahiptir (Dhiman ve Deb 2020).

Dünyada enerji sektörü endüstrilerinin çoğu yenilenebilir enerjiyi tercih etmektedir. Pandemi döneminde tüm dünya ekonomisindeki durgunluk ve enerji ihtiyacına olan ihtiyacın gün geçtikçe artması, yenilenebilir enerji kaynaklarına yapılan yatırımların önemini artırmaktadır. Yenilenebilir enerji kaynaklarının başında gelen rüzgar enerjisi de sürdürülebilir bir çevre politikası açısından, vazgeçilemez bir enerji kaynağı olmuştur. Rüzgar enerjisi, son dönemlerde en çok yatırım yapılan ve en hızlı gelişim gösteren enerji kaynaklarının başında gelmektedir. Bununla birlikte, değişen çevresel şartlar ve fosil yakıtların da sera gazı salınımını artırarak sebep olduğu küresel ısınmanın etkisiyle, rüzgar enerjisine yapılacak yatırımların belirlenebilmesi için, rüzgar enerjisi tahminleri büyük önem arz etmektedir. Rüzgar enerjisi tahmini, rüzgar türbinlerinden belirli bir zaman aralığında üretilebilecek enerji miktarının tahmini olarak tanımlanabilir. Üretilen enerji tahmini, aslında tahmini yapılacak olan güç değeridir (Karık vd. 2017).

Rüzgar enerjisi tahminleri, yatırım yapacak ve yaptığı yatırımın sürecini gözlemlemek, ona göre stratejisini ve enerji politikasını belirleyecek olan enerji dağıtım şirketleri tarafından kullanılmaktadır. Bu tahminler sayesinde, elektrik piyasası takasları, ekonomik yük sevkياتının takvimlenmesi mümkün kılınır (Dhiman ve Deb 2020).

Yatırım yapılacak ve rüzgar enerjisi sistemi kurulması planlanan bölgelere, yaklaşık bir sene önceden rüzgar hızı ölçümleri yapılır ve ileriye yönelik rüzgar hızı ve üretilebilecek olası rüzgar gücü projeksiyonları bu çerçevede yapılır. Fakat rüzgar hızları, bölgesel ve anlık hava koşulları çerçevesinde farklılıklar gösterir, dolayısıyla bu tahminlerin yapılabilmesi için kısa, orta ve uzun vadede olmak üzere çeşitli tahmin süreleri belirlenir (Dhiman ve Deb 2020).

Yapılan bu sınıflandırmalar, çalışmayı basitleştirerek doğru yöntemin seçilmesi adına önemlidir. Genellikle, kesinliği ve sağlamlığı açısından orta – kısa vadeli dönemdeki

yöntemler tercih edilmektedir. Fakat araştırmanın konusuna ve ulaşılmak istenen sonuca göre, diğer dönemsel yöntemler de kullanılabilir. Tahmin edilen değer ile rüzgar hızının veya gücünün gerçek değeri arasındaki fark, bazı standart hata terimleri kullanılarak ölçülebilir ve karşılaştırılabilir. Bu hata terimlerine, ortalama mutlak hata yüzdesi (MAPE), ortalama mutlak hata(MAE), ortalama hata karekökü (RMSE), ortalama mutlak hata (MAE) ve ortalama hata kare (MSE) örnek olarak verilebilir.

1.5.1 Rüzgar enerjisi tahmin yöntemlerinin farklı zaman dilimlerine sınıflandırılması

Genel olarak rüzgar enerjisi tahminleri dörde ayrılmaktadır. Bu tahmin aralıkları ise çok kısa süreli tahminler, kısa süreli tahminler, orta süreli tahminler ve uzun süreli tahminler olarak adlandırılır.

- Çok kısa süreli tahminler, birkaç saniyeden 30 dakikaya kadar olan zaman dilimindeki tahminleri tanımlar ve kullanım alanları arasında Türbin çalışması kontrolü, ve elektrik fiyatlarını düzenleme vardır (Chang 2014).
- Kısa süreli tahminler, 30 dakika ile 6 saat arasındaki zaman diliminde kullanılan tahmin çeşididir. Gün içi piyasa işlemlerinin yönetimi ve elektrik yükünün iletiminin planlanmasında kullanılır (Chang 2014).
- Orta süreli tahminler, 6 saat ile 24 saat aralığında belirlenen bir zaman diliminde gerçekleştirilen tahminlerdir. Gün sonu piyahasının düzenlenmesi için kullanılmaktadır (Chang 2014).
- Uzun süreli tahminler, 24 saat ile 168 saat veya daha uzun bir zaman dilimi için uygulanan tahminlerdir. Rüzgar çiftliklerinin bakımlarının yapılması amacıyla ve maliyet hesaplamasında kullanılır (Chang 2014).

1.5.2 Rüzgar enerjisi tahmin modellerinin sınıflandırılması

Rüzgar enerjisi tahmini için kullanılan yöntemler genel olarak 6 kategoride değerlendirilebilir ve bu kategoriler şunlardır;

- Süreklilik Yöntemi
- İstatistiksel Yöntemler

- Mekansal Korelasyon Yöntemi
- Yapay Zeka Yöntemleri
- Fiziksel Yöntemler
- Hibrit Yaklaşımlar

1.5.2.1 Süreklilik yöntemi

Bu yöntemin amacı, rüzgâr hızının veya gücünün tahmini yapılan değer ile gelecekteki gerçek değerinin aynı olacağı yönünde bir varsayım kullanmasıdır. Bu yöntem, rüzgar hızına bağlı olan rüzgar üretim değerleri arasındaki yüksek korelasyon değerine bakılarak yapılan tahminlere dayanır. Son bulunan tahmin değerinin, gelecekte gerçekleşecek değerler için de doğru olduğunu kabul ederek tahmini ilerleten bir yöntemdir. Çok kısa vadeli tahmin yöntemlerinde etkilidir, ancak geniş bir zaman ölçeği kullanıldığında, tahmin gücü düşen bir yöntemdir. Bu yöntemin en önemli özelliklerinden bir tanesi, ekonomik rüzgâr hızı veya gücünü tahmin eden yöntemlerinin başında gelmesidir. Elektrik şirketleri, çok kısa süreli tahminler için süreklilik yöntemini kullanırlar, bu nedenle geliştirilen herhangi bir yöntemin temelini oluşturan bir yöntem olduğu söylenebilir (Chang 2014).

1.5.2.2 Fiziksel yöntemler

Fiziksel Yöntemler, sıcaklık, basınç, yüzey direnci ve yer şekilleri (engeller) gibi hava tahmininde kullanılan verileri kullanır. Atmosfer ve sayısal hava tahminine dayanan bir yöntemdir. Sayısal Hava Tahmini modeli, büyük ölçekteki alanın hava tahminleri için meteorologlar tarafından geliştirilen bir yöntemdir. Genel olarak, yerel meteoroloji servislerinden alınan rüzgâr hızı verileri, rüzgâr türbinlerinde rüzgâr gücü verilerine dönüştürülür. Fazla miktarda veri kullanıldığı için, bu yöntemi uygulamak için çok güçlü bilgisayar sistemlerine ihtiyaç duyulmaktadır. Fiziksel Yöntemler, en doğru tahminleri yapabilmek ve atmosferin doğru tahmini için kullanılan doğru parametreleri kullanmaktadır (Chang 2014).

1.5.2.3 İstatistiksel yöntemler

İstatistiksel yöntemler, zaman serisi modelleri, yapay zeka tabanlı modeller, makine öğrenimi ve yapay sinir ağı yöntemleri ile rüzgar hızı ve rüzgar gücü tahmininde bulunan yöntemlerdir. İstatistiksel modeller, geçmişte ölçülmüş verileri kullanarak tahminde bulunur. Zaman serisi modeli olan Otoregresif Hareketli Ortalamalar yaklaşımı ile bir zaman serisi verisinde ARMA modeli serinin gelecek değerlerini anlamak ve tahminde bulunmak için kullanılır. İki kısımdan oluşan modelin otoregresif kısmı AR, diğer hareketli ortalamalar kısmı ise MA kısmıdır (Cantürk, 2018).

Otoregresif kısmı sayesinde, rüzgar enerjisi tahminlerinde kullanılabilirler. Otoregresif hareketli ortalamalar modelleri, George Box ve Gwilym Jenkins tarafından Box-Jenkins modeli olarak da bilinen ismiyle oluşturulmuştur. Bir zaman serisi kestirimi ve öngörme yöntemi olmakla birlikte, eşit zaman aralıklarından gözlenen zaman serisi verilerine uygulanan bir yöntemdir. Kısa zaman dilimleri için güçlü tahminler üretebilen istatistiksel yöntemler, aynı zamanda diğer modellere kıyasla geliştirilmesi daha kolay ve daha ekonomiktir. Süreklilik yöntemlerinde olduğu gibi, İstatistiksel Yöntemler de kullanılan zaman dilimi uzadıkça tahmin gücü azalacaktır. İstatistiksel Yöntemler arasında, AR, ARMA, ARIMA ve Bayes yaklaşımı yer almaktadır. Birbirine bağlı gözlem verilerinin olduğu mühendislik, ekonomi ve doğa bilimi problemlerinde, istatistiksel yöntemler etkili bir şekilde kullanılabilir. Rüzgar hızı tahminlerinde, ARMA modeli rüzgar hızları ardışıklık ve rasgeleliğe sahip olduğundan kullanılabilir. Geri yayılım yapay sinir ağı ile kurulan modelde ARIMA modeli, kısa zaman dilimleri için kurulan tahmin modellerinde etkilidir. Bayes yaklaşımı ise, hem rüzgar hızı hem de rüzgar gücü tahminlerinde kullanılabilen bir yöntem olarak literatürde yer almaktadır (Anonim 2018).

1.5.2.4 Hibrit yöntemler

Hibrit modeller, adından da anlaşılacağı üzere diğer tüm modellerin avantajlarından faydalanarak optimum bir performans elde etmek amacıyla kurulan modellerdir. Fiziksel ve istatistiksel yöntemlerin avantajlı yönlerini birleştirerek, hibrit bir tahmin modeli, rüzgar enerjisi tahminlerinde kullanılan bir hibrit yaklaşımdır. İstatistiksel

modellerin kısa süreli zaman dilimleri üzerindeki tahmin gücü ile, fiziksel yöntemlerin uzun süreli zaman dilimlerindeki tahmin gücü birleştirilerek, çıkarılan hibrit bir model rüzgar enerjisi tahminlerinde, optimum tahmin değerini elde etmek için önemli bir tahmin aracıdır (Cantürk 2018).

Bunlara ek olarak, fiziksel yöntemler ve yapay zeka yaklaşımları birleştirilerek oluşturulan hibrit modeller, istatistiksel yaklaşımları ve yapay zeka yaklaşımlarını birleştiren modeller ve yapay zeka yaklaşımlarının kendi arasında birleştirilerek oluşturulan hibrit modeller, kısa ve orta vadede yapılmış olan tahminlerde kullanılmıştır (Chang 2014).

1.5.2.5 Mekansal korelasyon yöntemleri

Mekansal Korelasyon Yöntemleri, farklı mekanların rüzgar hızları arasındaki mekânsal ilişki üzerinden hesaplamalar yapan bir yöntemdir. Bu yöntemde, rüzgar hızını tahmin etmek için, tahmin edilen noktanın ve komşu noktaların rüzgar hızlarının zaman serisi kullanılır (Chang 2014).

1.5.2.6 Yapay zeka yöntemleri

Son yıllarda, oyun sektörünün gelişmesi ile grafiksel işleme birimleri geliştirilmiştir. Grafiksel işleme birimleri sayesinde, vektör hesaplamaları ve matris işlemleri çok daha hızlı yapılabilir hale gelmiştir. Aylar sürebilen derin öğrenme işlemleri, bu grafiksel işleme birimleri sayesinde birkaç günde yapılabilmektedir. Günümüzde, işlenebilecek veri miktarının çok fazla olması ile derin öğrenme algoritmalarında kullanılan verilerin bu denli çok çeşitli ve fazla miktarında olması, derin öğrenme tekniklerinin günümüzde çok yaygın kullanılmasına ve hızla gelişmesine olanak sağlamıştır. Geliştirilmiş yeni yöntemler sayesinde, tahmin problemleri veri yoğunluğuna göre kısa sürelerde çözüme kavuşturulabilmektedir. Yapay Sinir Ağları, Uyarlanabilir Nöro-Bulanık Çıkarım Sistemleri, Bulanık Mantık Yöntemleri, Destek Vektör Makinesi , Nöro- Bulanık Ağ ve Evrimsel Optimizasyon Algoritmaları, geliştirilen yöntemler arasında yer almaktadır. Yapay Sinir Ağları, tahmin ve sınıflandırma ile ilgili karmaşık ve doğrusal olmayan problemlerle uğraşabilir. Yapay sinir ağları lineer olmayan problemlerin çözümünde

başarılıdır ve bu problemlerin çözümünde optimizasyon algoritmaları kullanılır. Yapay Sinir Ağları metotları arasında, geri beslemeli yapay sinir ağları (back propagation neural networks), tekrarlı sinir ağları(recurrent neural networks), radyal tabanlı yapay sinir ağları (radial basis function) ve ridgelet sinir ağı ve uyarlanabilir doğrusal eleman sinir ağı (ridgelet neural network, and adaptive linear element neural network) metotları yer alır (Chang 2014).



2. LİTERATÜR TARAMASI

Rüzgar enerjisinin gücünün tahmini, uygulanacak enerji politikaları açısından oldukça önemlidir. Özellikle kısa süreli tahminler, üretilen rüzgar enerjisinin dağıtımı ve gelen talepleri karşılayabilecek önlemleri almak açısından gereklidir. Bu bağlamda literatürde yer alan çalışmalardan bazıları şu şekilde yer almaktadır ;

Çevrimiçi SCADA (Supervisory Control and Data Acquisition) ölçümleri ile, rüzgar çiftliklerinin 48 saat sonraki rüzgar gücü üretimini tahmin etmek için sayısal hava ölçümlerinin, girdi olarak kullanılması ile tahmin yapılmıştır. İrlanda' da bulunan 5 rüzgar çiftliği üzerinden yapılan araştırmada, bulanık sinir ağı tahmin modeli kullanılmıştır (Kariniotakis vd. 1997).

2003 yılında Rosado ve Jimenez tarafından yapılan bir çalışmada ise, kısa vadeli rüzgar tahmin modellerine zaman serisi analizi yardımıyla bir bakış açısı sunulmuştur (Rosado ve Jimenez 2003).

2009 yılında Portekiz'de yapılan bir çalışmada, kısa süreli rüzgar enerjisi tahmini, üç katmanlı ileri beslemeli yapay sinir ağları kullanılarak modellenmiştir. Yapay sinir ağında, bir birim hiperbolik tanjant sigmoid transfer fonksiyonu kullanılmıştır. Gizli katmandan ve saf lineer transfer fonksiyonuna sahip bir birim çıktı katmanından oluşturulmuştur. Optimal sonucu elde edebilmek için, gizli katmanda 9 adet birim kullanılmıştır. Ortalama Mutlak Yüzde Hatası, %7,26 olarak hesaplanmıştır. Çalışma sonucunda, yapay sinir ağı modelinin rüzgar enerjisinin kısa süreli tahmininde etkili olduğunu göstermiştir (Catalao vd. 2009).

2016 yılında Çin'in başkenti Pekin'de yapılan bir çalışmada, 5-10 dakikalık bir zaman aralığındaki rüzgar gücü tahminleri kısa vadeli yapay dinir ağı tabanlı rüzgar enerjisi tahmin modeli kullanılarak tahmin edilmiştir. Tahminler, Goldwind rüzgar türbini SCADA sisteminden alınan gerçek rüzgar gücü verileri ile karşılaştırılmış ve tahminin hata payı çok düşük çıkmıştır. Model, yüksek doğruluk ile sonuçlandığı için tahmin edilen rüzgar gücü, yüksek rüzgar enerjisi penetrasyonuna sahip mikro şebekeler de,

gün öncesi kaynak planlaması için girdi miktarı olarak kullanılabilir olduğuna karar verilmiştir (Eseye vd. 2016).

2016 yılında, İran'ın Tahran kentinde yapılan bir çalışmada, 1 saatlik aralıklarla ölçülen rüzgar hızı veri seti kullanılan çalışmada, yapay sinir ağının dört tahmin yöntemi kullanılmıştır. Kullanılan dört adet tahmin yöntemi arasından (radyal tabanlı yapay sinir ağı, uyarlanabilir nöro-bulanık çıkarım sistemi, yapay sinir ağı ve genetik algoritmadan oluşan hibrit sistem ve yapay sinir ağı parçacık sürüsü optimizasyonu), Tahran bölgesindeki kısa süreli rüzgar hızlarını tahmin etmek için, en iyisinin yapay sinir ağı ve genetik algoritmadan oluşan hibrit sistem (Artificial neural network genetic algorithm hybrid) olduğu belirlenmiştir (Fazelpour vd. 2016).

2010 yılında Çin'de yapılan bir çalışmada, fiziksel metotlarla karşılaştırıldığında istatistiksel modellerin, küçük rüzgar çiftlikleri için daha uygun olduğu düşüncesi gelişmiştir. Klasik zaman serisi analizi yöntemlerine dayanarak, bu çalışmada yeni bir kısa dönemli tahmin yöntemi önerilmiştir. Önerilen bu yöntemde, çok adımlı yapılan tahminlerde ortalama görelî hata küçük çıkmıştır. Önerilen yöntem ayrıca, hem rüzgar hızını tahmin etmede, hem de rüzgar gücü tahminlerinde uygulanabilir bir yöntem olduğu sonucuna varılmıştır. Ayrıca çalışmada klasik zaman serisi metodu yerine, makalede önerilen algoritmanın hesaplama maliyetini artırmadan daha kesin bir tahmin yapabildiği belirtilmiştir (Liu vd. 2010).

2011 yılında Tayvanda yapılan bir çalışmada, bir enerji şirketinin gerçek verileri kullanılmıştır. Yapılan çalışmada metot olarak yapay sinir ağları ve genetik algoritmalar birlikte kullanılmıştır. Çalışmanın sonucunda yapay sinir ağları ve genetik algoritmaların kombinasyonlarının, fırtına oluşumu dışında, yani olağan üstü bir rüzgar durumu dışında, rüzgar gücü tahminini çok etkili bir şekilde yaptığı görülmüştür. Diğer yandan, yapay sinir ağının doğrusal olmayan haritalamada, iyi bir performans gösterdiği belirlense de, genetik algoritma ile olan kombinasyonunun çok daha iyi sonuç verdiği belirlenmiştir. Geliştirilen bu model sayesinde, açık elektrik piyasasında yapılacak işlemlerin daha güvenilir bir şekilde yapılabileceği öngörülmüştür (Kolhe vd. 2011).

2013 yılında yapılan bir çalışmada, bir rüzgar çiftğinde kısa zaman diliminde rüzgar gücü tahmininde kullanılan iki yöntem karşılaştırılmıştır. Bahsedilen iki yöntemden birisi yapay sinir ağı ile yapılan tahmin yöntemidir, diğeri ise fiziksel ve istatistiksel yöntemlere dayalı olan hibrit yöntemdir. Bu çalışmada iki yöntemin performansı kapsamlı bir şekilde karşılaştırılmıştır. Sonuç olarak, yapay sinir ağı modelinin tahmini hızlı bir şekilde gerçekleştirdiği görülmüş ve hibrit yönteme göre daha az maliyetli ve daha hızlı bir şekilde sonuç vermiştir. Bununla birlikte, hibrit modelin tahmin doğruluğu yapay sinir ağı yöntemine göre daha yüksek çıkmıştır. Yapılan çalışmada ayrıca tahmin hatalarının 5m/s rüzgar hızından düşük veya 15m/s den yüksek olduğunda daha düşük çıktığı görülmüştür (Peng vd. 2013).

Türkiye’de yapılan bir çalışmada, Mehmet Akif Ersoy Üniversitesi kampüsü içerisinde yapılan rüzgar ölçümlerinin kayıtları alınmıştır. Kayıtlar alınırken farklı çevresel faktörlerin etkileri de dahil edilmiştir (basınç, nem, sıcaklık, rüzgar hızı ve yönü). Çalışmada metot olarak, çok katmanlı algılayıcı ve radyal tabanlı fonksiyonlar kullanılmıştır. Çalışmada 100 adet yapay sinir ağı eğitilmiştir. Çalışmanın amacı, 61 metre yükseklikteki rüzgar hızını tahmin etmek üzeredir. Elde edilen değerlerin sonucu olarak, 61 metredeki rüzgar hızının tahmini çevresel faktörler (basınç, nem, sıcaklık, rüzgar hızı ve yönü) gözetildiğinde %99 doğrulukta olmuştur (Kirbas ve Kerem 2016).

Türkiye’de yapılan diğeri bir çalışmada yapay sinir ağları yöntemi ve Weibull dağılımı kullanılmıştır. Bozcaada’da seçilen rüzgar türbinlerinin farklı özelliklerine göre rüzgar gücü tahminlerinin modellenmesi yapılmıştır (Çelik ve Kolhe 2013).

Türkiye’nin batı illerinden biri olan Düzce’de yapılmış ve kısa vadeli elektrik yükünü tahmin etmek için yapay sinir ağlarını kullanan bir çalışma da, nisan ayı verileri temel alınarak, o aya ait girdi değerlerine göre tahmin üretilmiştir. Bu araştırmanın sonucunda, yapay sinir ağlarının doğrusal olmayan verilerde başarılı bir yöntem olduğu ve doğru tahminler üretebildiği belirlenmiştir (Öztürk ve Taşpınar 2019).

Türkiye’de yapılmış diğeri bir başka çalışmada ise, 2012 ve 2014 yılları arasındaki Türkiye elektrik piyasasından elde edilen veriler kullanılmıştır. Bu çalışmada kullanılan veriler, günlük ve haftalık zaman dilimlerindeki elektrik enerjisi talebini modellemek için

kullanılmıştır. Sadece sinüzoidal dalgalanmalara dayanan ve saatlik değişimleri öngören bu modelde, ekonomik veya meteorolojik herhangi bir veri kullanılmamıştır. Yıllık, haftalık ve günlük zaman dilimlerinde saatlik talebi tahmin etmek amacıyla doğrusal bir model kullanılmıştır (Yükseltan vd. 2017).

Başka bir çalışmada ise Fourier dönüşümlerine dayanarak Türkiye’de elektrik yükü modellenmesi yapılmıştır. Bu çalışmada, ARIMA zaman serisi ve Harmonik Regresyon karşılaştırması yapılmıştır. Sonuç olarak, Türkiye’nin elektrik yükü tahmininde klasik zaman serisi modeline göre bu çalışmada kullanılan modelin daha üstün olduğu belirtilmiştir (Akdi vd. 2020).

Türkiye’deki elektrik dağıtım şebekesinde uzun, orta ve kısa vadeli yük tahminleri için çok değişkenli uyarlamalı regresyon eğrilerine (MARS), ANN (Yapay Sinir Ağları) ve LR(Doğrusal Regresyon) modellerine dayalı üç model önerilmiş ve model tahminleri nem, rüzgar, yılın hangi günü ve sıcaklık değerlerine dayandırılmıştır. Bakıldığında MARS modeli, doğruluk ve kesinlik açısından LR ve ANN modellerinden daha iyi performans göstermiştir (Nalçacı vd. 2019).

Dört farklı yapay sinir ağı modeli oluşturulmuş bir çalışmada ise, mevsimselliğin etkileri ve aylık Türkiye elektrik yükü eğilimini tahmin etmek için, modeller arasında performansa göre seçim yapılmıştır. Diğer taraftan, Yapay Sinir Ağı(YSA) Modelinin kabulünü ve güvenilirliğini geliştirmek amacıyla, SARIMA modeliyle YSA modeli karşılaştırılmıştır. Modelin amacı, Türkiye’nin 2015-2018 yılları arasındaki aylık elektrik tüketimini tahmin etmek amacıyla kullanılmıştır (Hamzaçebi vd. 2019).

Son dönemde Türkiye’de yapılan bir çalışmada, Türkiye’deki günlük elektrik yükünün tahmini ve istatistiksel modellenmesi amacıyla 5 Ocak 2021 ile 26 Aralık 2021 arasındaki veriler baz alınmıştır. 2022 yılında yayınlanan ve Kamil Demirberk Ünlü tarafından yapılan çalışmada, 1 ila 7 gün arasındaki tahmin yükleri araştırılmış ve derin öğrenme tekniklerinden LSTM, GRU, BLSTM ve CNN modelleri karşılaştırılmıştır. Hesaplanan algoritmaların performanslarını ölçmek adına, R^2 , RMSE ve MAE performans metrikleri kullanılmıştır. Tahmin sonuçlarına göre performansı iyi olan algoritma, LSTM olarak belirlenmiştir. 1 günlük kısa süreli tahminler için LSTM algoritmasının R^2 değeri 0.94’tür. Tahmin süresi 7 güne kadar uzatıldığı takdirde algoritmanın performansı düşerek R^2 değeri 0.73 olarak ölçülmüştür (Ünlü 2022).

3. TEZİN AMACI, ÖNEMİ VE YÖNTEMİ

Karbon bazlı kaynakların tükeniyor olmasından dolayı alternatif yeşil enerji kaynaklarının önemi artmaktadır. Güneş, rüzgar, jeotermal, hidroelektrik ve biokütle yenilenebilir enerji kaynaklarından bazılarıdır. Rüzgar enerjisi, onlarca yıldır birçok gelişmiş ülkede elektrik üretimi için kullanılmakta olup, Türkiye’de önemi ve kullanım oranları son yıllarda birçok teşvikle artmaktadır. Bu tezde, derin öğrenmeye dayalı tek değişkenli bir model kullanılarak, Türkiye'deki rüzgar santrallerinde üretilen miktarının modellenmesi ve tahmin edilmesi amaçlanmaktadır. Çalışmanın tahmin aralığı kısa dönemlidir. Önerilen modelin gücü; tahminde bulunmak için yalnızca kendi gecikmesine ihtiyaç duymasındır. Ampirik kanıtlar, modelin kısa vadede yüksek R^2 değerine sahip olduğunu göstermektedir.

Elektrik, ülkelerin büyümesinde ve gelişmesinde en önemli faktörlerden biridir. Elektrik, hayatımızın her alanında tüketilmektedir. Elektrik enerjisinin en belirgin özelliği depolanamamasıdır. Bu nedenle, elektrik arz ve talebi takip edilmelidir. Ayrıca elektrik yüklerinin modellenmesi ve tahmininin yapılması, sistemin düzgün işlemesi ve tutarlı üretim planlamalarının yapılabilmesi için önemlidir. Yapay zekanın, bu tür tahmin problemlerine entegre edilmesi ve etkin bir şekilde kullanılması, günümüzün bir gerekliliğidir.

Derin öğrenme, birçok algoritma içeren istatistiksel tahmin ve modelleme için kullanılan teknikler kümesidir. Bu algoritmalar arasında bulunan yapay sinir ağları, örnekler üzerinde pratik yaparak gerçek değerli, vektör değerli veya ikili çıktıyı tahmin etmek için kullanılan pratik bir yöntemdir.

Derin öğrenme, denetimli ve denetimsiz öğrenme olarak ikiye ayrılabilir. Yapay sinir ağları; denetimli öğrenme olarak sınıflandırılır. Denetimli öğrenmede, algoritmaya girdilere karşılık gelen etiketlerde sağlanır. Algoritma daha sonra doğru çıktıyı tahmin etmek için, kullanıcı tarafından sağlanan durumları kullanır.


Bu çalışmada LSTM, BLSTM, GRU ve CNN algoritmaları günlük üretilen rüzgar gücü tahmini için kullanılmıştır. Seçilen dört algoritma da, zaman serileri analizlerinde ve

zellikle elektrik yk tahminlerinde kullanılmıř ve bařarılı olmuř yntemlerdir. Bu yntemlerin daha nceki alıřmalarda kullanımı ve sonuları, literatr bařlıęı altında referans kullanılarak paylařılmıřtır. Kullanılan algoritmalar arasından en yksek doęrulukta tahmin gc olan algoritma arařtırılmaktadır. Algoritmaların kıyaslanabilmesi iin performans metrikleri tanımlanmıřtır. Performans metriklerinin hesaplamasında, hiper parametreler hesaplayıcı tarafından belirlenmiřtir. En iyi performansı gsteren algoritma gnlk rzgar enerjisi yknn tahmininde kullanılarak, kısa vadeli enerji politikalarının alınmasına ve enerji piyasalarının doęru tahmin verileri zerinde alıřmasına olanak saęlamaktadır.



4. YAPAY SİNİR AĞLARI


Yapay Sinir Ağları, insan beyninin yapısından esinlenerek ortaya çıkarılan matematiksel modelin, insan beyninin işlevlerini yerine getirmesini taklit etmesine denir. Yapay sinir ağlarının yapısında aynı şekilde insan beynindeki nöronlar gibi nöronlar bulunmaktadır. Bu nöronların, bilgi işleme ve iletme birimleri gibi görevleri vardır. Yapay Sinir Ağları, katmanlı yapılardır ve katman sayısı çözümü aranan problem için optimum düzeyde belirlenir. İlk yapay sinir ağı modeli 1943 yılında, bir nöroloji hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir (Mijwil 2017). Şekil 4.1’de biyolojik nöron ve yapay sinir ağında kullanılan yapay nöronun yapısı ve benzerliği görülmektedir.



Şekil 4.1 Nöronun yapısı (Sarıöz 2022)

Biyolojik olarak insanlardaki nöron, bir sinir hücresi olup, sinir sistemleri için temel işlevsel birimi sağlamaya yarar. Biyolojik nöronlar, temelde birbirleri ile iletişim kurabilmek için sinapslar boyunca elektrokimyasal uyarıları bir hücreden diğerine iletmekle görevlidirler. Uyarının eşiği, sinaptik yarıktan kimyasalların salınımını harekete geçirecek kadar büyükse, yani eşik değerin üzerinde ise, kimyasallar salınır ve iletim sağlanabilir. Biyolojik nöronlar yapısı gereği birçok dendrit içerirler ancak, sadece bir akson içeren hücre gövdesinden oluşurlar. Aksonlar, yapısal olarak sinir


liflerinden oluşan lifli yapılardır. Diğer taraftan, tek olan akson yüzlerce kez dallanabilir. Dallanan yapılar olan dendritler, ana hücre yapısından çıkan ince yapılardır (Aggarwal 2018).



Şekil 4.2 Nöronun anatomisi (Fountas 2022)

Sinir biliminin temel ilkeleri, yapay sinir ağlarının geliştirilmesinde çok önemli bir esin kaynağıdır. Biyolojik nöronlardaki sinaptik bağlantılar, işlevsel benzerlikleri açısından yapay sinir ağlarında aynı rolü üstlenen ağırlıklar aracılığıyla birbirlerine bağlanırlar. Bu mimari sayesinde yapay sinir ağlarında giriş nöronlarından hesaplanan değerler ağırlıkları ara parametreler olarak kullanarak çıkış nöronlarına iletimini sağlar. Ağırlıklarına buradaki rolü öğrenmeyi devamlı kılmaktır. Yapay Sinir Ağlarında ağırlıkların değiştirilmesi ile öğrenmenin devam etmesi durumu biyolojik öğrenme ile aynı şekildedir. Nasıl ki biyolojik öğrenmede dışarıdan bir uyarı ile gelen girdi değerleri biyolojik nöronların uyarılması sayesinde bir nörondan diğerine iletilen ağırsı yapılar sayesinde oluyorsa, aynı şekilde yapay sinir ağlarında da, bir dış uyaran vardır ve ağırlıklandırma yöntemi ile öğrenilecek fonksiyonun girdi-çıkı çiftlerinin örneklerini içeren veri setleri kullanılır. Örneğin, görüntü işleme üzerine bir eğitim verisi araba ve motosiklet piksel görüntüleri içeriyorsa, çıkı kategorisi hakkında tahminler yapmak için

giriş temsilleri kullanılarak yapay sinir ağında işlenir. Belirli bir girdi için tahmin edilmeye çalışılan çıktının, doğruluğun derecesine bağlı olarak sinir ağındaki ağırlıkların doğruluklarına yönelik geri bildirim alınır. Yapay Sinir Ağında herhangi bir aşamada gerçekleşecek olan hatayı biyolojik bir organizmada bir tür hoş olmayan bir geri bildirim olarak görebiliriz. Sonuç olarak yapay sinir ağlarında görüntü işleme evresinde gerçekleşen bir hatanın insanlarda olan karşılığı ise yanlış bir cisim görme, bozuk görme biçiminde oluşmasıdır. Ağırlıklar doğru şekilde değiştirilerek ve daha fazla girdi-çıkı çiftiyle beslenen ağlar daha doğru sonuçlar üretirler, böylece öğrenmenin gücü artmış olur. Aynı şekilde yine motosiklet ve araba görüntüsü tanımlama üzerinden bir örnek verilecek olursa, insan beyni ne kadar çok ve çeşitli türden araba ve motosiklet görüntüsü görmeyi tecrübe ederse, iki görüntüyü doğru bir şekilde birbirinden ayırt edebilmesi yetisi, yani öğrenme gücü o kadar artacaktır. Şekil 4.3'te, tipik bir makine öğrenme algoritmasının doğruluğu ile, çok katmanlı bir yapay sinir ağının doğruluğu arasındaki fark açıkça görünmektedir. Derin Öğrenmenin temelini oluşturan Yapay Sinir Ağları sayesinde karmaşık yapılar ve doğrusal olmayan kompleks problemlere kısa sürelerde çözüm üretilebilmektedir (Aggarwal 2018).



Şekil 4.3 Eğitilmiş modellerin performans ölçümlerinin karşılaştırılması (Shimpi 2019)

Yapay sinir ağları, üç temel kısımdan oluşurlar. Bu kısımlardan ilki, girdi kısmıdır, girdiler ikinci kısım olan gizli katman veya birbirine bağlı düğümlerde işlenerek çıktı olarak üçüncü kısma bağlanır. Her bir düğüm, diğer bir düğüme bağlanır ve ilişkili bir ağırlık ve eşığe sahiptir. Herhangi bir düğümün çıktısı, belirtilen bir eşik değerinden büyük değere sahipse, o düğüm etkinleştirilir ve gizli katman içerisindeki bir katmandan diğerine veri akışını sürdürür. Eşik değerine ulaşamayan düğüm çıktısı, gizli katman içerisindeki bir katmandan diğerine iletim sağlayamaz (Aggarwal 2018).

Yapay Sinir Ağları, eğitim verilerine bağlı olarak doğruluklarını güncelleyen yapılardır. Her düğüm, ağırlıklar (w_i) kullanılarak birbirine bağlanır. Her bir gizli katmanı besleyen özel ağırlık w_0 ise, çıktı katmanını da özel bir ağırlık olan z_0 ile beslenir. Bu ağırlıklar önyargı olarak işlenir. Girişler (x_i) giriş katmanını aracılığıyla ağa girer. Herhangi bir dönüşüm olmadan veri noktaları sistemi besler. Ayrıca gizli katmanların sapsmasını sağlamak için “1” değerini alan x_0 ile gösterilen özel bir girdi değeri vardır. Bu girdiler, gizli katmanlardaki her nota ağırlıklı toplam olarak dönüştürülür.

$$\sum_{j=0}^d w_{hj} x_j$$

burada h indeksi gizli birimin konumunu temsil eder ve j , giriş biriminin indeksidir. Hesaplanan ağırlıklı toplamlar, aktivasyon fonksiyonlarına uygulanır. Uygulamalarda standart aktivasyon fonksiyonları olarak sigmoid (σ), ReLu ve tanh fonksiyonu kullanılır. Bunlar sırasıyla şu şekildedir:

$$\sigma(a) = \frac{1}{1 + e^{-a}},$$

$$\text{ReLu}(a) = \text{Max}(0, a)$$

ve

$$\tanh(a) = \frac{e^a - e^{-a}}{e^a + e^{-a}}$$

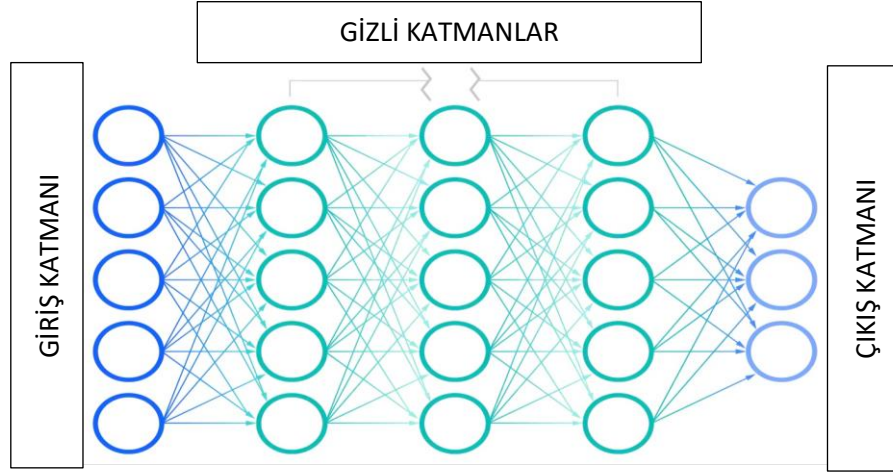
h' inci gizli birimden i' inci çıkışa çıkış ağırlığı v_{ih} ile gösterilirse. i . birimdeki aynı hesaplamaları kullanarak şu şekilde formüle edilebilir:

$$y_i = \sum_{h=0}^H v_{ih} z_h.$$

Ağları eğitmek için geri yayılım algoritması kullanılır. Bu algoritmanın ana fikri, ağırlıkları güncellemek için gradyan inişi kullanmaktır. Burada algoritmalar, maliyet fonksiyonunu minimize etmeye çalışır. Algoritma, yerel minimumu bulmak için maliyet fonksiyonunun kısmi türevlerini kullanır. Her ağırlığın katkısını belirler ve katkılarına göre gradyan inişini kullanarak bunları günceller. Maliyet fonksiyonunu minimum yapmayı amaçlayan bu yöntem sayesinde, hata miktarı en düşük seviyede tutularak, elde edilen tahmin değeri ile gerçek değer arasında fark minimize edilmiş olur.


Kendini güncelleyen ve doğruluğunu artıran bu yapılara algoritmalarla destek olan yapay zeka ve bilgisayar bilimi de aynı zamanda gelişmiş GPU lar sayesinde işlem hızlarını her geçen gün artırmaktadırlar. Çok katmanlı sinir ağı yapıları bu algoritmalara bir örnektir ve öğrenme katmanlarda gerçekleşir. Şekil 4.4'de çok katmanlı bir yapay sinir ağının yapısı bulunmaktadır (Aggarwal 2018).

Günümüzde işlenebilecek veri miktarının fazlalığı sayesinde gerçeğe çok yakın tahminler üreten derin öğrenme algoritmaları ve yapay sinir ağı metotları sıklıkla tercih edilmektedir. Bu yöntemler sayesinde insan gibi davranabilen robotlar, sürücüsüz ulaşım sağlayabilen araçlar, gerçeğe çok yakın meteorolojik tahminler ve gerçek değerine çok yakın rüzgar enerjisi üretimi tahminleri yapabilmek mümkündür (Aggarwal 2018).



Şekil 4.4 Çok Katmanlı Yapay Sinir Ağı (Anonymous 2020a)

Gizli katmanların sayısı ve ağırlıklandırmalar, araştırmayı yapan kişi tarafından optimize edilir. Tüm ağırlıklandırılmış girdiler, gizli katmanlarda toplandıktan sonra bulunan değerlere araştırmacı tarafından belirlenen aktivasyon fonksiyonu uygulanır. Daha sonra, girdilerin değiştirilmiş ağırlıklı toplamları aktivasyon işlemi de gerçekleştikten sonra ek nöronlara aktarılır. Gizli katmanlarda işlem görüldükten sonra, en son aşamada çıktı katmanından bir değer oluşur. Optimum sonuca ulaşılan kadar bu işlemler tekrarlanır. Aslında, yapay sinir ağlarındaki en temel hesaplama birimleri, lojistik regresyon ve en küçük kareler regresyonu gibi bilinen makine öğrenimi algoritmalarından esinlenerek türetilmiştir ve en temel birimi algılayıcı (perceptron) olarak adlandırılır. Algılayıcı yapısı Şekil 4.5'deki gibi basit bir yapıdır.



Şekil 4.5 Perceptron Modeli (Minsky-Papert 1969)


Yapay sinir ağlarında farklı birimlerin ağırlıkları, ortaklaşa öğrenen ve kendini güncelleyerek öğrenme gücünü artıran yapılardır. Birbirinden farklı birimleri birbirine bağlar ve öğrenme gücünü ağırlıkların değiştirilmesi yoluyla artırır. Bu yapı, birden fazla birimi birbirine bağlamadan, yalnızca en temel birim kullandığında, öğrenme algoritmaları klasik makine öğrenimi modellerine indirgenmiş olur. Çok katmanlı birden fazla birimi birbirine bağlayan karmaşık sinir ağı yapıları ile temel makine öğrenimi yöntemleri arasındaki ilişki bu şekilde açıklanabilir (Aggarwal 2018).

Zaman Serisi analizinde yapay sinir ağından oldukça fayda sağlanır. Yapay sinir ağlarında ARIMA modellerinden farklı olarak durağanlığı sağlamak için, analiz edilen verilere ihtiyaç duyulmaz. Yapay Sinir Ağları, karmaşık yapıda ve doğrusal olmayan sistemleri, aktivasyon fonksiyonları sayesinde daha iyi bir şekilde analiz edebilir. Yapay Sinir Ağlarının bir avantajı da, eğitim verileri üzerinde çalışarak vektör değerli ve gerçek değerli veya ikili çıktıyı tahmin etmede optimum bir yöntem sağlamasıdır. Bu durum denetimli öğrenme olarak adlandırılır. Denetimli öğrenmede, etiketli girdiler kullanılarak algoritma çalıştırılır. Araştırmacı tarafından sağlanan durumları kullanan algoritma, uygun sonuçları tahmin edebilir. Yapay Sinir Ağı, gerçek değerli hedef fonksiyonlu regresyon modeli için ve ikili hedef işlevleriyle sınıflandırma için kullanılabilir. Perceptronun aksine çoklu gizli katmana sahip yapay sinir ağlarına, çok katmanlı yapay sinir ağları adı verilir. Çoklu gizli katmana sahip olan çok katmanlı yapay sinir ağları, çok katmanlı ileri beslemeli yapay sinir ağlarını içerir. Doğrusal davranış gösteren durumların tahmininde perceptron kullanılır fakat, doğrusal davranış göstermeyen durumların tahminlerinde aktivasyon fonksiyonları kullanılarak, ağırlıklandırılan veriler doğrusal olmayan çıktılara dönüştürülür ve doğrusal olmayan tahmin problemlerinde kullanılır. Birçok doğrusal olmayan tahmin problemlerinin çözümünde, İleri Beslemeli Yapay Sinir Ağı (FFNN) kullanılır. Modelde geri besleme bağlantıları varsa, yapay sinir ağı, Tekrarlı Yapay Sinir Ağları (RNN) olarak adlandırılır (Aggarwal 2018).

4.1 İnsan Beyni ve Yapay Sinir Ağları Arasındaki İlişki

Beyin, farklı işleyişleri ve özellikleri olan 4 ayrı lobdan oluşmaktadır. Farklı görevleri üstlenen bu lobların isimleri Şekil 4.6'da görüldüğü üzere, Ön (Frontal) lob, Yan (Parietal) lob, Arka baş (okspital) lob, ve şakak(temporal) lobdur (Anonim 2021).

Ön (Frontal) lob, bilinçli düşünme yetisine sahip olmamızı sağlar, dolayısıyla zarar görmesi halinde ruh halimizde değişiklikler gözlenebilir. Yan (Parietal) lobunun görevi ise, duyu organlarından gelen bilgilerin birleştirilmesidir. Bunun yanında Yan (Parietal) lobunun bir görevi de, mekansal görüş işlemesi(visuospatial processing) yardımı ile nesne kullanımının doğru bir şekilde sağlanmasıdır. Arka baş (okspital) lob, görme duyusuyla ilgili sinirler aracılığı ile gelen bilgilerin işlendiği lobdur ve zarar görmesi halinde görme bozuklukları ve halüsinasyonlar gelişebilir. Son olarak, şakak(temporal) lobun görevi ise, yüz tanıma, mekan tanıma, ses ve koku duyularının algılanması gibi görevlerdir (Anonim 2021).



Şekil 4.6 İnsan beyni (Anonim 2021)

Yapay zeka, beynin biyolojik yapısından esinlenir ve işleyiş olarak aynı beynin biyolojik yapısında olduğu gibi sinirsel iletim ve işleme sayesinde karmaşık yapıları tanımlar ve çözümler. İnsan beyninin temel lobları ve üstlendikleri görevlerin, yapay

sinir ağlarında benzer şekilde karşılıkları vardır. Örneğin, temporal lobun beyin yapısına olan katkısı, yapay sinir ağlarındaki ağırlıkların yapay sinir ağına olan katkısına benzetilebilir. Yapay Sinir Ağlarındaki ağırlıklar, uzun süreli belleği temsil etmesi ve aynı şekilde temporal lobun da bu görevi biyolojik insan beyininde üstlenmesinden ötürü, benzer yapılar olduğu söylenebilir. Bir diğer benzerlik ise, oksipital lobun CNN'ler ile olan benzerliğidir. CNN'ler görüntü ve nesnelerin tanımlanmasında en etkili yapay sinir ağı sistemleridir, bu özelliklerinden dolayı oksipital lob ile çok benzer yapılar olduğu söylenebilir. Beynin lobları ve yapay sinir ağları arasında diğer bir benzerlikte ön lob ile RNN arasındadır. İnsan beyininde ön lobun birincil işlevi kısa süreli hafızadır, aynı şekilde RNN'lerde kısa süreli bellek olarak işlevlerini yerine getirirler. Önceki gözlemleri hatırlayarak, hatırladıkları bu bilgileri ileriye yönelik kullanan yapay sinir ağı türüdür ve bu özelliklerinden ötürü, beyin ön lobu ile benzerlik gösterirler (Anonymous 2018b, Anonim 2021).

4.2 Tekrarlı Yapay Sinir Ağları (Recurrent Neural Network)

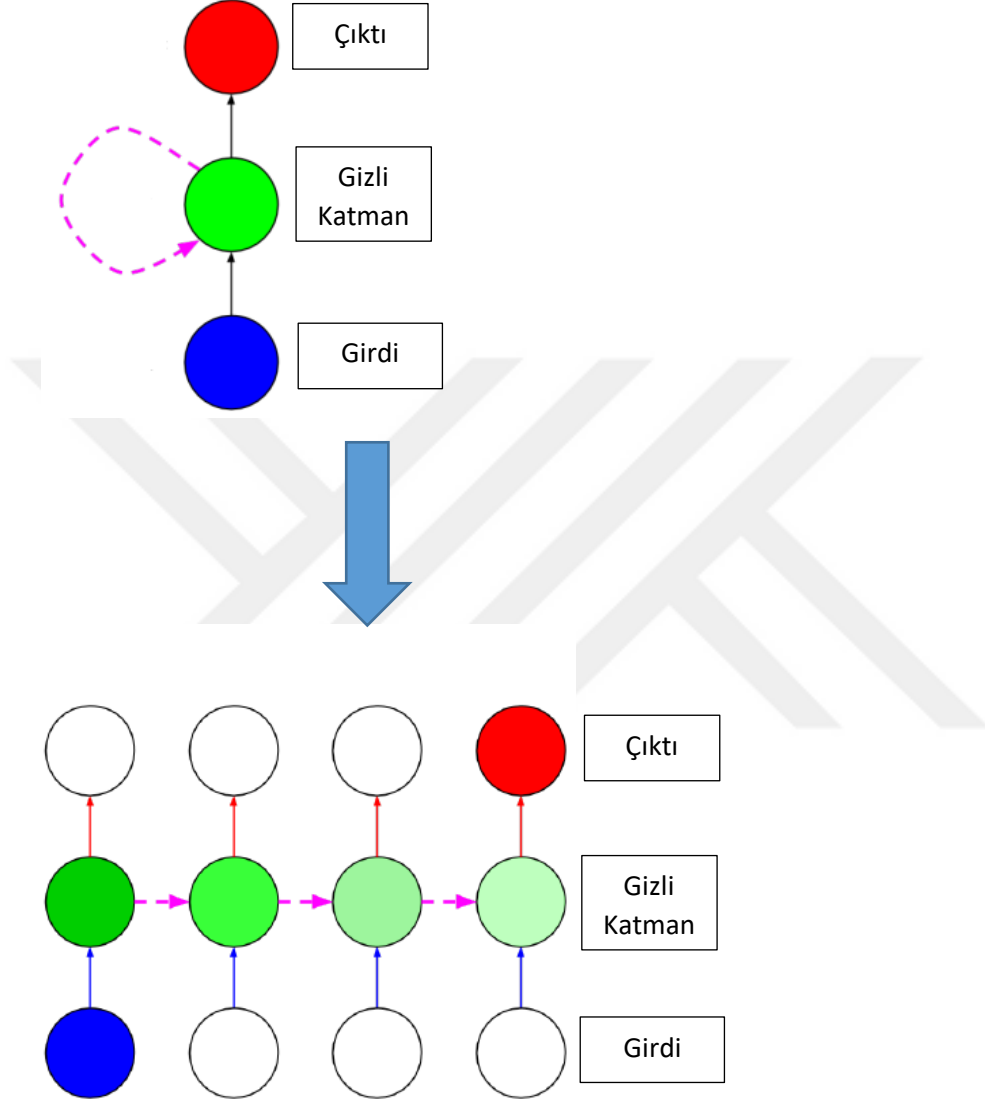
Tekrarlı Yapay Sinir Ağları, metin ve resim sınıflandırmaları yapılırken ve zaman serisi verileri kullanılırken etkili sonuçlar üretir. Döngü içeren yapay sinir ağlarının bir avantajı olarak, bilgi korunarak zaman içerisinde tekrar kullanılabilmesi söylenebilir. Tekrarlı Yapay Sinir Ağlarında, girdiler çıktı olarak kullanılabilir, yani ağ tahmin amacıyla kullanılacak geri besleme döngülerine sahiptir. Tekrarlı Yapay Sinir ağını inşa etmenin yolu ise, birçok özdeş ağın birbirine mesaj göndermesi ve birbiriyle iletişim kurmasıdır. Bir dezavantaj olarak Tekrarlı Yapay Sinir Ağları, gradyan kaybolması (gradient vanishing) problemini yaşayabilir. Bu soruna yönelik uygulanan çözümler arasında LSTM yer almaktadır. Gradyan kaybolması sorunu ilk olarak 1991 yılında Sepp(Joseph) Hochreiter tarafından keşfedilmiştir. Tekrarlayan Sinir Ağlarının zamansal bağımlılıkları çıkabilir, bu nedenle tekrarlayan ağlar, örneğin zaman serisi analizi, konuşma işleme gibi sinyallerinde zamansal gecikmeler içeren uygulamalar için kullanılır. Tekrarlayan ağların bir özelliği de, gereken çıktıyı üretmek için hangi geçmiş girdilerin depolanması gerektiğini öğrenmesi gerektiğidir. Özellikle gradyan tabanlı sistemlerde, hata sinyalinin yeterli bir girdi depolaması için geçmiş girdilere geri besleme bağlantıları üzerinden zamanda geriye doğru akması gerekir. Bu durumda, geleneksel geri yayılım algoritmaları çok uzun öğrenme sürelerine maruz kalır. Zaman

içerisinde geri yayılım veya gerçek zamanlı tekrarlayan öğrenme ile, zamanda geriye doğru olan hata sinyalleri kaybolma eğiliminde olur. Dolayısıyla, yeterli olmayan ağırlık değişiklikleri nedeniyle de öğrenmek zorlaşır. Yapılan son çalışmalarda, tekrarlayan ağlar için uzun süreli gecikme problemlerini geleneksel öğrenme algoritmalarının öğrenemeyeceği kanısına varılmıştır. Bununla birlikte, LSTM gibi gelişmiş metotlar 1000 adımlık zaman gecikmelerini içeren uzun zaman gecikmesi problemlerinde iyi performanslar göstermiştir (Hochreiter 1998).

Şekil 4.7’de gradyan kaybolmasının aşamalarını gösteren görsel mevcuttur. Görselin anlatmaya çalıştığı durum, maliyet fonksiyonu hesaplandıktan sonra ağırlıkları güncelleme aşamasına geçilir ve bu nedenle maliyet fonksiyonunu ağ üzerinden geri yayma işlemi gerçekleştirilir. Maliyet fonksiyonunu ile ilişkili çıktının hesaplanmasında kullanılan her bir nöron, hatayı en aza indirmek için ağırlıklarla güncellenir. Şekil 4.7’de görüldüğü üzere, zamanla sadece çıktı katmanının altında görünen nöronlar değil, tüm nöronlara kadar yayılım sağlanır. Bu sebepten ötürü, tekrarlanan ağırlık güncellemesi burada problemi yaratmaktadır. Bilindiği üzere, ilk başta atanan ağırlıklar sıfıra yakın rastgele değerlerdir ve zamanla yayılımın bu şekilde olması ile çarpım değeri çok küçük değerlere indirgenir ve ağırlık öğrenme yetisi zayıflamış olur. Gradyan düşüş ne kadar düşük olursa, ağırlık güncellemesi ve en uygun noktaya ulaşması o kadar zor olur. Örneğin, t zaman noktası için en uygun ağırlıkları elde etmek için 1500 devir yeterli olabilir, ancak bu noktada düşük eğim nedeniyle Şekil 4.7’de en soldaki nöron üzerinde görünen $t-3$ zaman noktası için ağırlıkları eğitmek için yetersiz kalabilir. Ancak buradaki asıl sorun, sadece ağırlıkların uygun şekilde eğitilememesi değildir. Bu noktadaki asıl sorun, tekrarlı yapay sinir ağlarında önceki katmanların çıktıları sonraki katmanlar için girdi olarak kullanıldığından dolayı, t zaman noktası için eğitim, gradyan kaybolması probleminden dolayı iyi eğitilemeyen katmanlardan gelen girdilere dayalı olarak eğitilir, ve bu durum da tüm ağırlıkların düzgün bir şekilde eğitilememesine neden olur. Kaybolan gradyan probleminde ağırlıklar ne kadar ileri giderseniz, gradyanınız o kadar küçüleceğinden ağırlıklardaki diğer tüm ağırlıklara domino taşı etkisi ile yayılır ve bu durum da ağırlık eğitimini kademe kademe daha da güçleştirir.

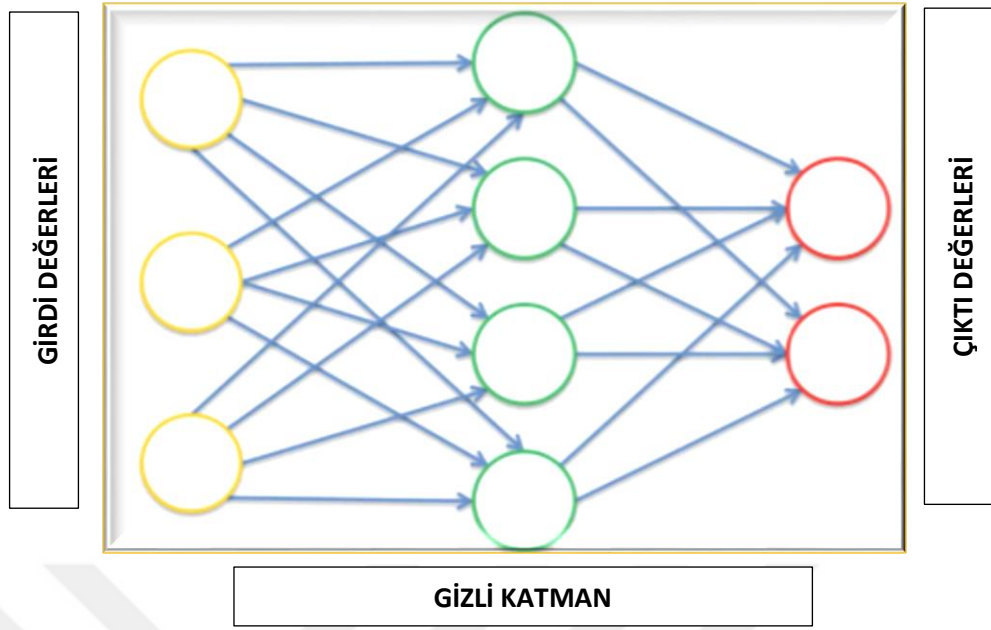
Kaybolan gradyan durumunu ortadan kaldırabilmek için, LSTM kullanmanın dışında, ağırlıklar sıfırlanarak gradyan potansiyelini en aza indirerek, ağ yeniden

çalıştırılabilir ya da yine kaybolan gradyan problemini çözmek için tasarlanmış olan Echo State Networks kullanılabilir. Fakat bu çözümlerin arasında en bilineni LSTM'dir.



Şekil 4.7 Gizli katmanlar boyunca ağırlığın “1” den küçük olması durumunda ilk adımdaki girdinin son adımdaki çıktı üzerinde etkisinin hızla azaldığını yeşil rengin açılan renk tonları ile gösteren bir kaybolan gradyan problemi (Lipton 2015)


LSTM, bir RNN çeşidi olmakla birlikte, normalde uzun vadeli ilişkiler hakkında bilgi edinmeye yarar. Basit bir yapay sinir ağının nasıl RNN'e dönüştürüldüğü 5 adımda gösterilebilir.



Şekil 4.8 Çok katmanlı yapay sinir ağının Tekrarlı yapay sinir ağına dönüşmeden önceki hali (Anonymous 2020b)

1. Adım


İlk adımda Şekil 4.8’deki çok katmanlı sinir ağı katmanları görsel olarak sıkıştırılmış ve tek düğümler halinde şekil 4.9’daki duruma getirilmiştir. Fakat bu yapı indirgenirken katmanlar aynı şekilde kalır (Anonymous 2020b).



Şekil 4.9 Çok katmanlı yapay sinir ağının tek katman halinde gösterimi (Anonymous 2020b)

2. Adım


İkinci adımda, tek tek ağırlıklandırılan ve düğümler arasındaki sinirsel iletimin gösterimi olan oklar teke indirilir ve vektör konumuna Şekil 4.10’daki gibi getirilir (Anonymous 2020b).



Şekil 4.10 Vektör gösterimi (Anonymous 2020b)

3. Adım


Üçüncü adımda, vektörel gösterimi görselleştirmek adına Şekil 4.10 dikey konuma Şekil 4.11'deki gibi getirilir (Anonymous 2020b).



Şekil 4.11 Dikey vektör gösterimi (Anonymous 2020b)

4. Adım

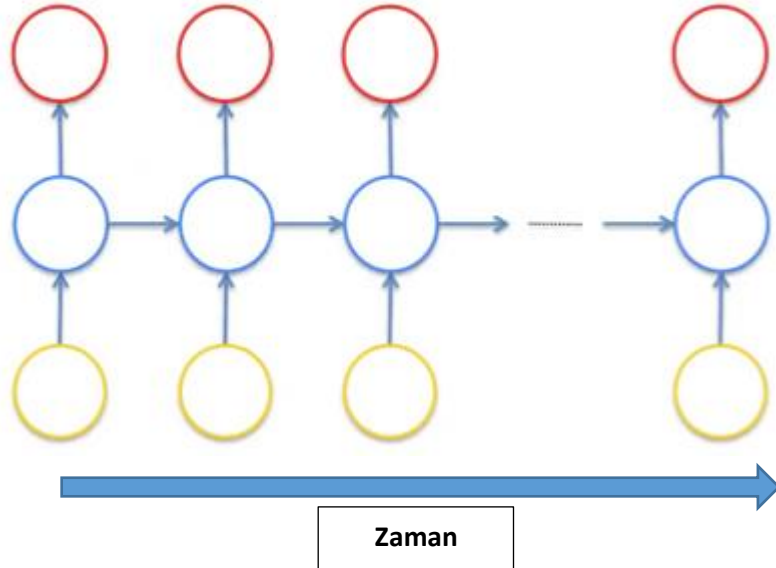
Bu adımda ise, geçici döngüyü temsilen bir satır eklenir, bu ekleme Şekil 4.12'deki gibi bir RNN gösterimidir ve ifade etmeye çalıştığı durum, gizli katmanın yalnızca çıktı vermediği aynı zamanda verdiği çıktının kendi içinde geri besleme yaptığı anlamına gelir (Anonymous 2020b).



Şekil 4.12 En basit haliyle Tekrarlayan Yapay Sinir ağı gösterimi (Anonymous 2020b)

5. Adım

Son adımda ise zamansal döngü açılır ve RNN'ler en yeni haliyle gösterilir. Şekil 4.13, her bir daire tek bir nöronu değil, birden fazla nöron içeren bir nöron katmanının gösterimidir (Anonymous 2020b).



Şekil 4.13 Tekrarlayan Yapay Sinir ağı gösterimi (Anonymous 2020b)

Özetle, geleneksel modelde girdiler, gizli katman ve çıktılar mevcuttur fakat, zamanla nöronlarda birbirlerine bağlanacaktır. RNN'lerin arkasında yatan fikir, nöronların bir tür kısa belleğe sahip olması sayesinde, önceki adımlarda ne olduğu hatırlayarak, gelecekte birbirlerine bu bu bilgiyi aktarıp süreçleri daha etkili bir şekilde analiz edebilmeleridir. Tekrarlı Yapay Sinir Ağları, en etkili ve ileri düzey algoritmalara sahip derin öğrenme tekniklerinden biridir (Anonymous 2020b).

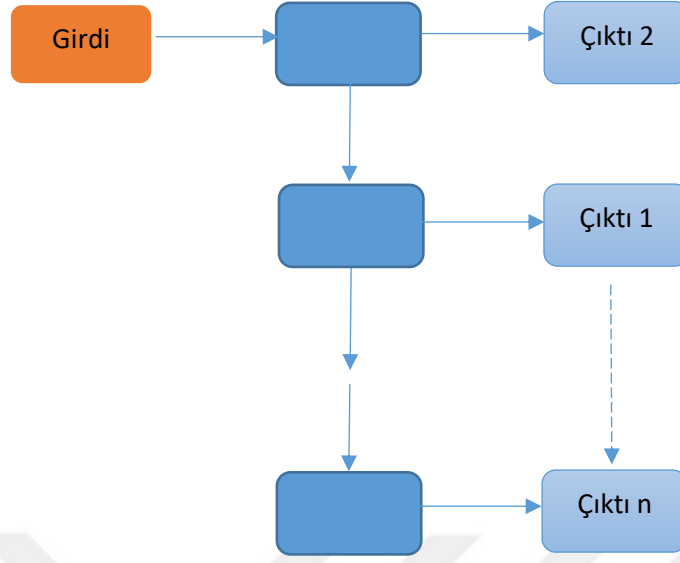
4.2.1 Tekrarlı yapay sinir ağları tipleri

Tekten teke (one-to-one), en basit tekrarlayan yapay sinir ağı türüdür ve tek bir giriş ve tek bir çıkışa izin veren bir yapıya sahiptir. Geleneksel bir yapay sinir ağı yapısında olduğu gibi, sabit bir giriş ve çıkış boyutlarına sahiptir. Görüntü sınıflandırma problemlerinin çözümünde kullanılabilir. Şekil 4.14'de tekten teke tekrarlayan yapaya sinir ağı yapısı bulunmaktadır (Bajwa 2022).




Şekil 4.14 Tekten teke (one-to-one) tekrarlayan yapay sinir ağı gösterimi (Bajwa 2022)

Tekten yığına (one-to-many) tekrarlayan yapay sinir ağları, tek bir girdi ile birden çok çıktısı olan yapılardır ve sabit bir girdi boyutuna sahip olup, bir dizi veri çıkışı üretir. Tekten yığına tekrarlayan yapay sinir ağları, genelde müzik üretimi ve resim altyazısı için kullanılan bir tekrarlayan yapay sinir ağı tipidir. Aşağıdaki Şekil 4.15'de tekten yığına tekrarlayan yapaya sinir ağı yapısı bulunmaktadır (Bajwa 2022).



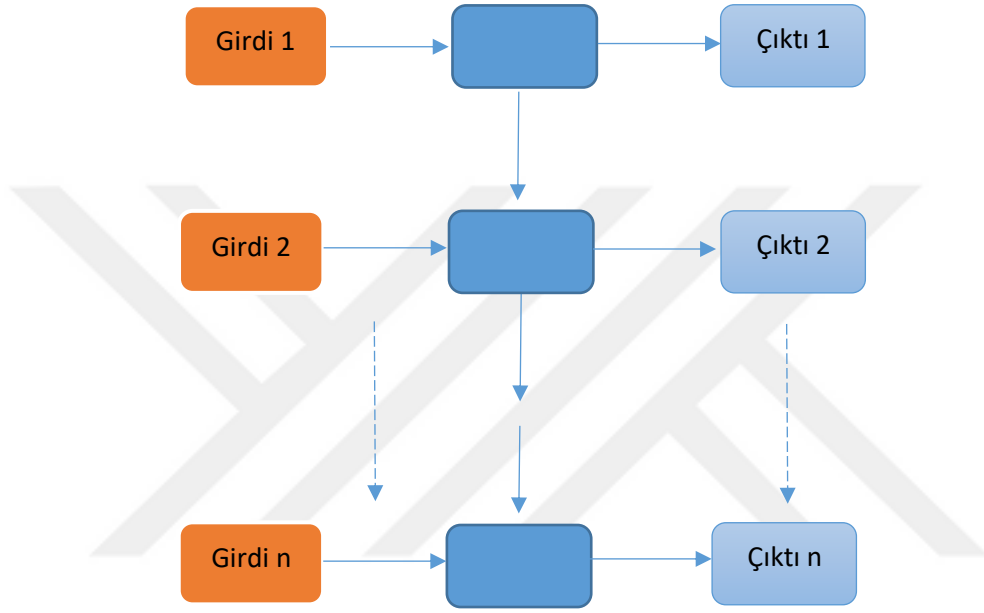
Şekil 4.15 Tekten yığına (one-to-many) tekrarlayan yapay sinir ağı gösterimi (Bajwa 2022)

Yığından teke (many-to-one) tekrarlayan yapay sinir ağları, birden fazla girdi olduğunda ve bu girdiler için tek bir çıktı üretildiği durumlarda kullanılan bir türdür. Özetle, sabit bir girdiyi görüntülemek adına bir girdi yığını gerekir. Duygu sınıflandırması yapılırken kullanılan bir tekrarlayan yapay sinir ağı modelidir. Şekil 4.16'da yığından teke tekrarlayan yapay sinir ağı yapısı görseli bulunmaktadır (Bajwa 2022).




Şekil 4.16 Yığından teke (many-to-one) tekrarlayan yapay sinir ağı gösterimi (Bajwa 2022)

Yığından yığına tekrarlayan yapay sinir ağları ise, bir girdi dizisinden bir çıktı dizisi oluşturmak amacıyla kullanılır. Bu tekrarlayan yapay sinir ağı modeli, eşit birim boyutu ve eşit olmayan birim boyutu olmak üzere iki alt kategoriye ayrılır. Eşit birim boyutuna sahip modelde, hem giriş hem de çıkış birimlerinin sayısı aynıdır ve varlıkların adlandırılmasında kullanılır. Şekil 4.17’de Eşit birim boyutuna sahip model görseli bulunmaktadır (Bajwa 2022).



Şekil 4.17 Eşit birim boyutuna sahip yığından yığına tekrarlayan yapay sinir ağı gösterimi (Bajwa 2022)

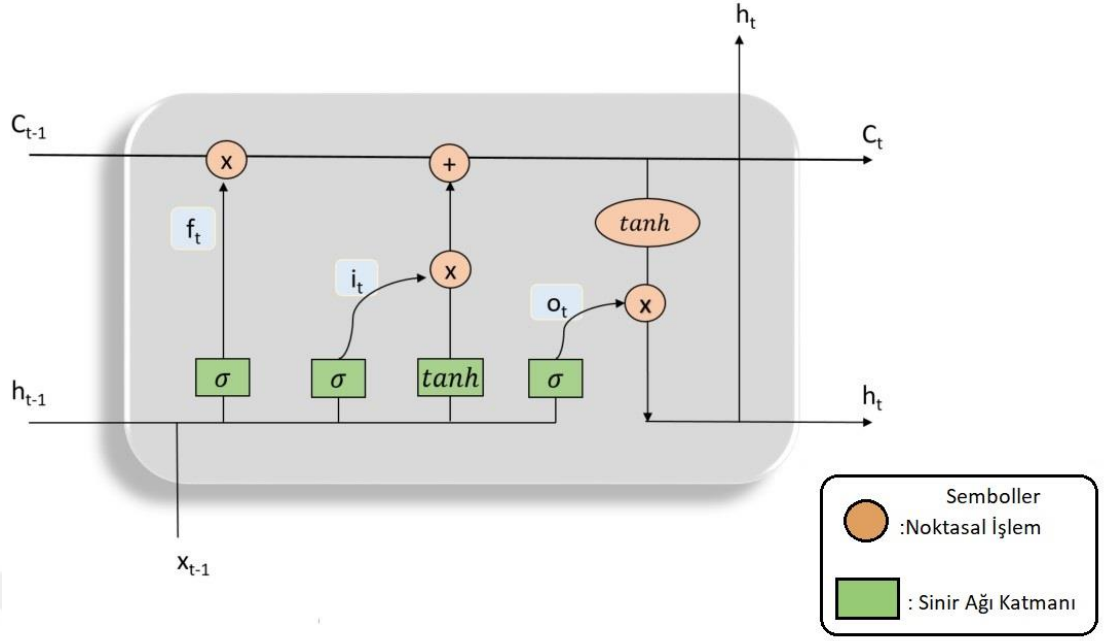
Eşit birim boyutuna sahip olmayan modelde ise, hem giriş hem de çıkış birimlerinin sayısı birbirinden farklıdır ve bu model makine çevirisinde kullanılır. Şekil 4.18’de Eşit birim boyutuna sahip olmayan modelin görseli yer almaktadır (Bajwa 2022).



Şekil 4.18 Eşit birim boyutuna sahip olmayan yığından yığına tekrarlayan yapay sinir ağı gösterimi (Bajwa 2022)

4.2.2 Uzun kısa süreli bellek (Lstm)

Uzun Kısa Süreli Bellekler, kaybolan gradyan sorunu ile başa çıkmak adına oluşturulmuş yapılardır. Hatayı yapay sinir ağı üzerinde iletirken, zaman içerisinde ağırlıklar aracılığıyla birbirine bağlanan gizli katmanların çözülmemiş geçici döngüden geçmesi gerekir, fakat bu ağırlık kendi üzerine defalarca uygulandığında eğimin hızla düşmesine neden olur. Yani en soldaki(girişe yakın) katmanların ağırlıkları, en sağdaki(çıkışa yakın) katmanlara göre çok daha yavaş güncellenir ve bu nedenle ağın eğitilmesi çok güçleşir. Bu şekilde tekrarlayan ağlarda oluşan gradyan sorununa LSTM'ler çare olarak üretilmiştir.



Şekil 4.19 Uzun Kısa Süreli Bellek (LSTM) gösterimi (Ünlü 2022)

LSTM’lerde uzun vadeli bağımlılık durumundan özellikle kaçınılır. Uzun süreli bellek tutmak LSTM’ler için doğal bir süreçtir ve bu durumu sürdürmek için herhangi bir ekstra çabaya ihtiyaç duymazlar. Şekil 4.20’de görüldüğü üzere, bellek hücrecini belirten ve t zamanına kadar olan bilgileri kodlamak için kullanılan C_t parametresi ile gösterilir. Bir bellek hücrecinin aktivitesi, devre şemasına göre üçe ayrılır. Bunlar sırasıyla giriş kapısı, unutma kapısı ve çıkış kapısı olarak adlandırılır ve f_t , i_t ve o_t ile şekildeki gibi gösterilir. Bu üç kapı için ise kurulan denklemler aşağıdaki gibidir:

$$f_t = \text{sigmoid}(V_f h_{t-1} + U_f x_t + b_f)$$

$$i_t = \text{sigmoid}(V_i h_{t-1} + U_i x_t + b_i)$$

$$o_t = \text{sigmoid}(V_o h_{t-1} + U_o x_t + b_o)$$

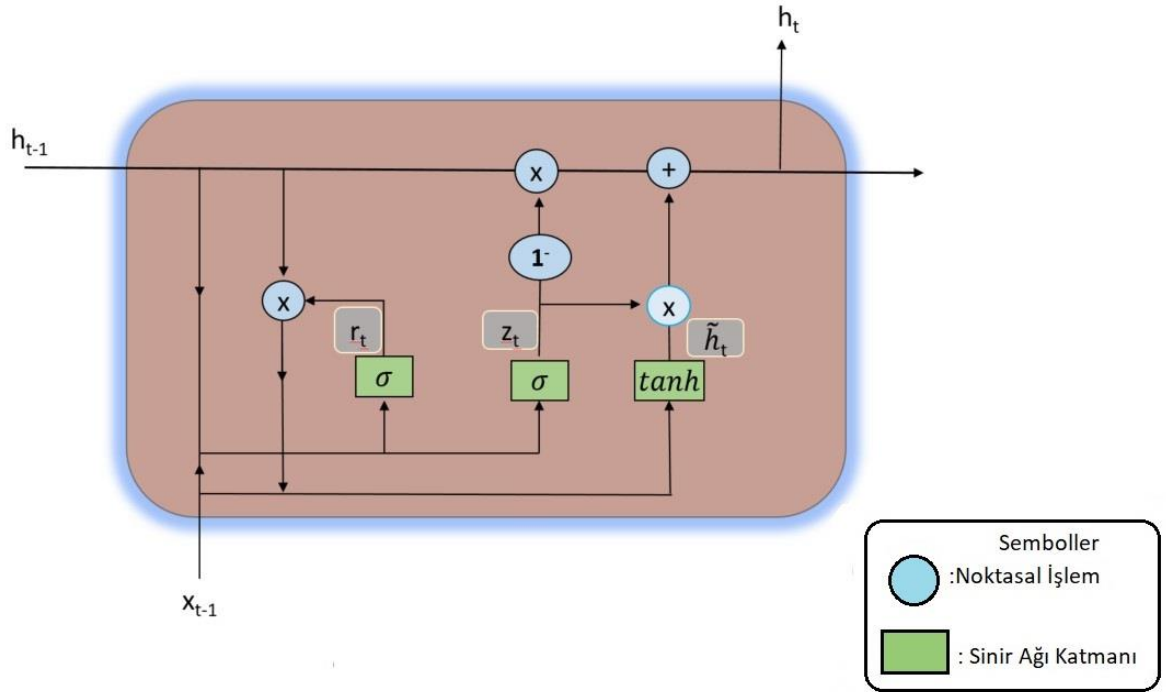
Güncelleme denklemlerinin geri kalanları ise aşağıdaki gibi gösterilir.

$$c_t = f_t * c_{t-1} + i_t * d_t, h_t = o_t * \tanh(c_t)$$

$$c_t = f_t * c_{t-1} + i_t * d_t$$

Yukarıdaki denklemlerde bileşen bazında çarpma işlemini göstermek için “*” ifadesi kullanılmıştır.

Hücrelere bilgi eklemek için giriş kapısı kullanılır, bilgiyi kaldırmak için ise unut kapısı kullanılır. Çıkış kapısı ise, önceki adımda giriş olarak kullanılacak bilgiyi hücreye seçmekle görevlidir. İlk unutma kapısı, t zamanında x_t girişinin ve önceki gizli katman h_{t-1} 'nin bir fonksiyonu olarak bilgi edinir. Eğer unutma kapısındaki değer "1" e yakınsa, son bellek hücresi olan C_{t-1} korunacaktır. Eğer bu şekilde olmaz ise, veriler silinecektir. İkinci durumda elde edilen yeni bilgi, eski bilgi ile giriş kapısını oluşturmak için birleştirilir. Yani, yeni bir C_t oluşturmak için bellek hücresine dönüştürülür. Son durumda ise çıkış kapısı, bir sonraki gizli durumu oluşturmak için ve hangi bilgilerin kullanılacağını çıkış kapısı belirler. GRU'da LSTM gibi kaybolan gradyan sorununa çözüm olarak gösterilmektedir. LSTM'nin giriş ve unut kapıları, hem giriş hem de unut kapıları olarak hizmet veren tek bir güncelleme kapısı ile GRU algoritması sayesinde birleştirilebilir. Şekil 4.20'de bir GRU hücresinin temsilen gösterimi mevcuttur.



Şekil 4.20 Kapılı Tekrarlayan Birim gösterimi (Ünlü 2022)

GRU modeline iki adet ek kapı eklenerek mimarisi geliştirilmiştir. Sıfırlama ve güncelleme kapıları olarak iki tür kapı mevcuttur. Kapıların görevi bilgileri depolamak

ve gerekli olduğunda ileriye aktarılmasını sağlamaktır. Aşağıda model yeni kapılar kullanılarak oluşturulan GRU modelidir.

$$r_t = \text{sigmoid}(U_r h_{t-1} * x_t),$$

$$z_t = \text{sigmoid}(U_z h_{t-1} * x_t),$$

$$\tilde{h}_t = \text{tanh}(U_r r_t h_{t-1} * x_t),$$

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

Zamandan tasarruf sağlamak ve GRU'nun performansını artırmak adına, sıfırlama ve güncelleme kapıları artırılabilir. Önceki evreden toplanan bilginin kaybolup kaybolmamasına sıfırlama kapısı ve gizli katman karar verir.

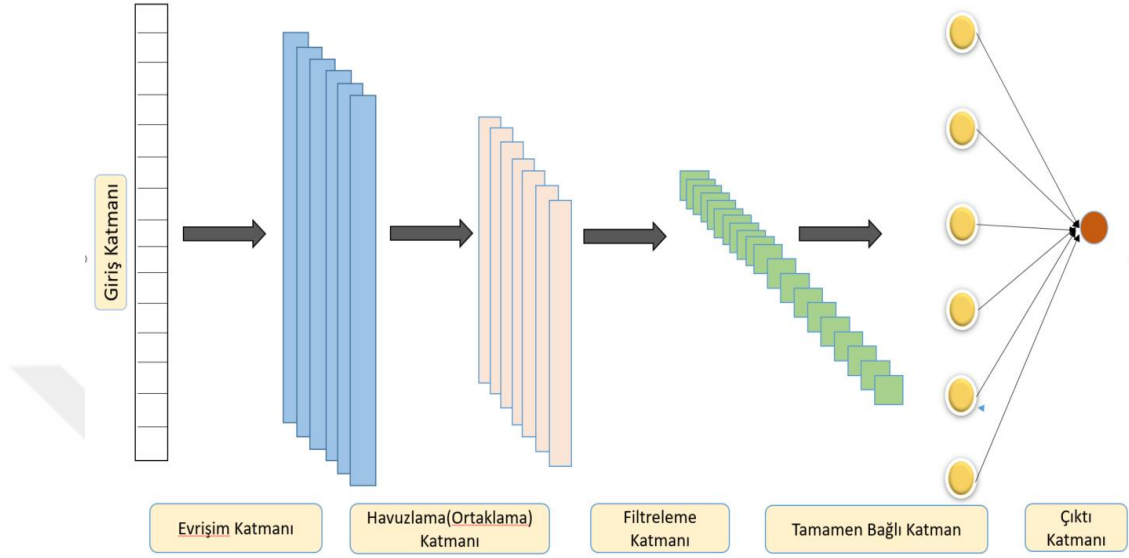
4.2.3 İki yönlü uzun kısa süreli bellek (blstm)

BLSTM, sinir ağını gelecekte geçmişe ve geçmişten geleceğe olacak şekilde, iki yönde de sekans bilgisine sahip olmasını sağlayan yöntemdir. Girdi değeri, normal LSTM modelinden farklı olarak iki yönde de akmaktadır. Diğer bir deyişle, girdi değeri normal LSTM modelinde geriye doğru veya ileriye doğru tek yönlü akar, fakat BLSTM modelinde girdi değeri geçmiş ve gelecek bilgileri korumak adına iki yönlü akmaktadır (Verma 2021).

4.2.4 Evrişimli sinir ağları

Evrişimli Sinir Ağları, görüntü çözümüleme, video yayınları gibi ızgara tipi katmanlı yapılara sahip veriler üzerinde çok iyi sonuçlar alabilen bir ağ türüdür. Ağın adındaki evrişim kelimesi, matematiksel süreci ifade etmektedir. Çevremizdeki nesnelere, insanları ya da bir görüntü içerisindeki arka planda yer alan nesnelere nasıl algıladığımız, evrişimli sinir ağları yapısına çok benzer yapılardır. İlk defa görülen bir nesneyi, ilk anda kategorize edip algılamakta güçlük çekmenin nedeni, önceki zaman diliminde beynin o görüntüyü işleme üzerine pratiğinin olmamasından kaynaklıdır. Evrişimli Sinir Ağları 5 adımda süreci katmanlarla yürütür. Şekil 4.21'de görüldüğü

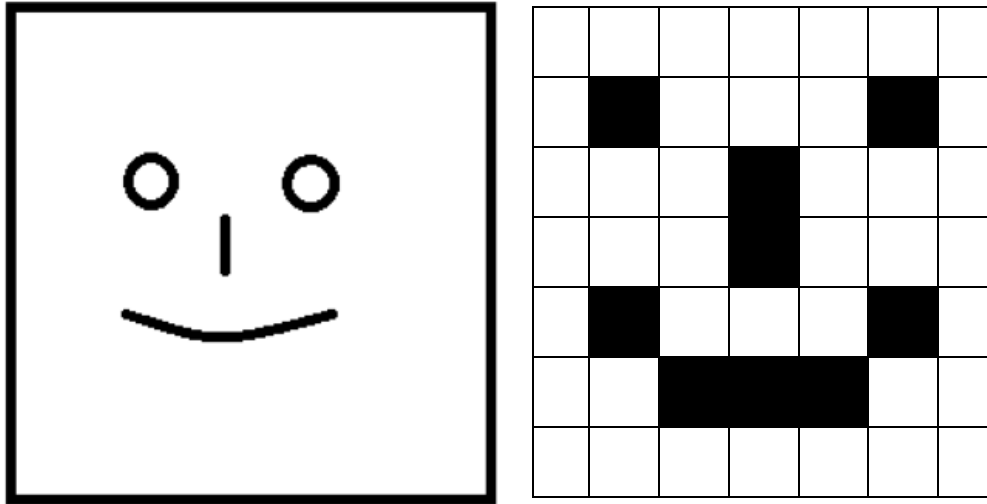
üzere bu katmanlar sırasıyla, evrişim katmanı, havuzlama(ortaklama) katmanı, filtreleme katmanı, tamamen bağlantı katman ve çıktı katmanlarıdır (Ünlü 2022).



Şekil 4.21 Evrişimli Yapay Sinir Ağı gösterimi (Ünlü 2022)

Evrişim, verilen iki fonksiyondan birinin şeklinin, diğeri tarafından nasıl değıştirildiğini ifade eden ve entegrasyon yoluyla türetilen özel bir fonksiyona verilen isimdir.

Evrişimli Sinir Ağlarında, ilk katman evrişim katmanıdır ve evrişim katmanları girdiyi sararak bir sonraki katmana iletmekle görevlidir. Bu durum görsel korteksteki belirli bir uyarana tepki veren nörona benzer. Evrişimsel her bir nöron, sadece kendi alıcı alanında bilgiyi işlemektedir. Örneğin, bir fotoğrafı tanımlamada kullanılan evrişimli sinir ağında, evrişim katmanında kullanılan üç unsurdan birincisi fotoğrafın kendisidir. İkincisi özellik dedektörüdür, ve fotoğraftaki kullanılacak özellikleri yakalayan bir matristir. Üçüncüsü ise öznitelik haritasıdır. Şekil 4.22’de evrişimsel bir sinir ağının insan gülümsemesini tanımlamaya çalışmasının görselidir. Sadeleştirmek amacı ile görsel, insan gülümsemesinin temsiline yansıtılmaktadır. Gerçek görüntü tanımlamaları çok daha karmaşık olarak çözümlenmektedir (Anonymous 2018b).



Şekil 4.22 Gülümseme ifadesinin dedektör matrisi gösterimi (Anonymous 2018b)

Şekil 4.22’de sağ taraftaki görselde gülen yüzü ifade eden pikseller işaretlenmiştir. Görselde matematiksel mantık olarak gülen yüzü ifade eden piksellere “1” değeri verilmiştir. Görselin olmadığı boş piksellere ise “0” değeri atanmıştır. Gülümseme ifadesini evrimsel sinir ağının algılayabilmesi için, gülümseme ifadesinin “0” ve “1” atamaları ile gülümseme ifadesinin şekline benzeyen bir kalıp öğretilmiştir. Şekil 4.23’de “0” ve “1” atamaları ile gülen yüz şeklini oluşturan matris yer almaktadır. Giriş görüntüsünde yer alan “1” değerlerinin oluşturduğu kalıba dikkatli bakıldığında gülen yüz ifadesi görülebilir. Özellik algılayıcı olarak 5×5 veya 7×7 matrisler ile de çalışabilir fakat geleneksel yöntem olarak genelde 3×3 matris kullanılır. Özellik algılayıcı, literatürde “kernel” veya “filtre” adıyla da yer alır (Anonymous 2018b).

Giriş Görüntüsü							Özellik Algılayıcı		
0	0	0	0	0	0	0	0	0	1
0	1	0	0	0	1	0	1	0	0
0	0	0	1	0	0	0	0	1	1
0	0	0	1	0	0	0			
0	1	0	0	0	1	0			
0	0	1	1	1	0	0			
0	0	0	0	0	0	0			

Şekil 4.23 Giriş görüntüsü matrisi ve özellik algılayıcı gösterimi (Anonymous 2018b)

Şekil 4.24'deki gibi özellik algılayıcıyı kullanırken, giriş görüntüsü matrisi üzerine sol üst köşeden yerleştirilerek eşleşen hücre sayıları hesaplanır. Eşleşen hücreler sonraki aşama da özellik haritasının sol üst hücresine eklenir. Bu işlem, giriş matrisinde her seferinde bir hücre sağa doğru ilerleyerek tekrarlanır. Her seferinde bir hücre hareket edildiği için, bu duruma bir piksellik adım denir. Giriş Görüntüsü Matrisi ile Özellik Algılayıcı Matrisi hücreleri birebir çarpılarak toplanır, dolayısıyla Özellik Matrisinde sadece “0” lar ve “1” ler olmayacaktır. Özellik algılayıcı yerine literatürde “kernel” veya “filtre” tanımlarının geçmesi gibi, Özellik Haritası içinde “Aktivasyon Haritası” terimi literatürde kullanılan terimlerden bir tanesidir (Anonymous 2018b).



Şekil 4.24 Giriş görüntüsü matrisi ve özellik algılayıcının eleman-eleman çarpımı (Anonymous 2018b)

Şekil 4.22'de verilen örnek basit bir örnektir, gerçekte evrişimli sinir ağları çoklu özellik algılayıcılar geliştirir ve bu algılayıcıları evrişimli katmanlar olarak adlandırılan çeşitli özellik haritalarını türetmek için kullanır. Bu işlemin amacı, evrişimli sinir ağının görüntüleri doğru bir şekilde tarayabilmesi ve daha doğru bir şekilde kategorize edip, hangi özelliklerin önemli olduğunu belirlemesi içindir. Bu sayede, özellik algılayıcılarını geliştirir hatta, birçok durumda ağ tarafından göz önünde bulundurulmuş özellikler, insan gözü tarafından fark edilemez ve yeterli miktarda eğitildikleri takdirde karmaşık görüntüleri çözümleyebilirler. Aşağıdaki fotoğraflarla birlikte verilen özellik haritaları şekil 4.25, şekil 4.26 ve şekil 4.27'de yer almaktadır. Şekil 4.25'deki keskin bir görüntü elde etmek için uygulanan filtrenin özellik haritası, şekil 4.26 ve şekil 4.27'de kullanılan filtrelerin özellik haritasından farklıdır. Şekil 4.26 ve şekil 4.27'de

sırasıyla bulanık olarak filtrelenen görüntünün özellik haritası ve kenar algılayıcı filtre uygulanan görüntünün özellik haritası mevcuttur (Anonymous 2018b).



0	0	0	0	0
0	0	-1	0	0
0	-1	5	-1	0
0	0	-1	0	0
0	0	0	0	0

Şekil 4.25 Fotoğraf görüntüsünü keskinleştiren filtre ve filtreye ait özellik haritası gösterimi (Anonymous 2018b)



0	0	0	0	0
0	1	1	1	0
0	1	1	1	0
0	1	1	1	0
0	0	0	0	0

Şekil 4.26 Fotoğraf görüntüsünde kenar algılayıcı filtre uygulaması ve filtreye ait özellik haritası gösterimi (Anonymous 2018b)



	0	1	0	
	1	-4	1	
	0	1	0	

Şekil 4.27 Fotoğraf görüntüsünü keskinleştiren filtre ve filtreye ait özellik haritası gösterimi (Anonymous 2018b)

4.2.4.1 Evrişimsel sinir ağında aktivasyon fonksiyonu kullanımı

Aktivasyon Fonksiyonları, bir etkinleştirme işlemi gerçekleştiren fonksiyonlardır. Aktivasyon fonksiyonları, doğrusal modellerle çözülemeyen karmaşık yapıların kategorize edilmesinde, çözümlenmesinde ve doğrusal olmayan çözümler üreterek karmaşıklığı ortadan kaldırmakla görevlidir (Anonymous 2018b).

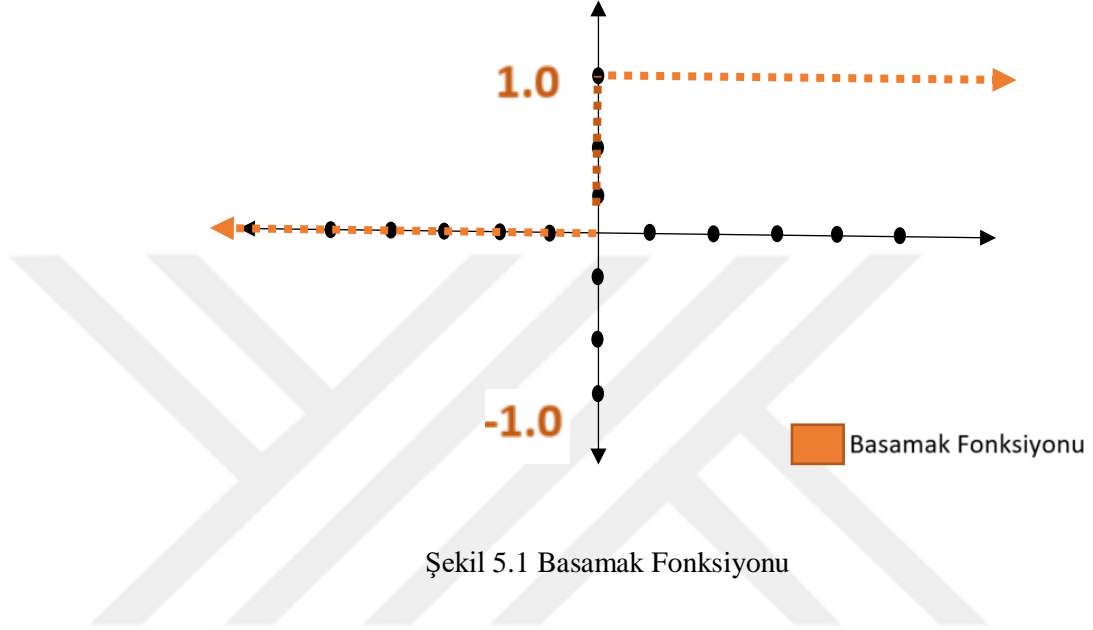
Aktivasyon fonksiyonları, sinir ağlarında bilginin bir nöronun bir sonraki nörona aktarılıp aktarılmayacağına karar veren yapılardır. Derin öğrenmede, sinir ağlarının etkin bir şekilde eğitilebilmesi, doğru sonuçlar alınabilmesi, hesaplama maliyetlerini düşürülebilmesi ve ağın tahmin ve taklit yeteneğinin artırılabilmesi için aktivasyon fonksiyonları önemlidir. Derin öğrenme algoritmalarında aktivasyon fonksiyonları kullanılmadığı takdirde, algoritmanın öğrenme derinliği belirli bir seviyeye kadar olabilmektedir ve yeterli olmamaktadır. Yani aktivasyon fonksiyonunun kullanılmadığı durumlarda, sonuçlar doğrusal modeller olacaktır. Doğrusal fonksiyonlar ise, tek dereceli polinomlardır. Fakat derin öğrenmede kullanılan sinir ağları, video, yazı, ses gibi karmaşık dünya problemleri içeren yapıları çözmek için kullanılır ve doğrusal yapılarla bu problemleri çözüme kavuşturmak çok güçtür. Bu durumda, birden fazla dereceye sahip olan doğrusal olmayan fonksiyonlar tercih edilir. Derin Öğrenme

algoritmalarında, parametreleri güncellemek ve ağın öğrenmesini sağlamak amacıyla geri yayılım(backpropagation) algoritması kullanılır. Güncelleme işlemi sonuçlandığında, fonksiyonların türev değerleri gelir ve derin öğrenme modellerinde bu nedenle aktivasyon fonksiyonlarının türevlenebilme özelliğine sahip olmaları gerekir. Aktivasyon fonksiyonunun, derin öğrenme algoritmalarına bir diğer katkısı da “1” ile “-1” arasındaki herhangi bir giriş değerinin çıkış değerini normalleştirmeye yardımcı olur. Yapay sinir ağı milyonlarca veri noktasında eğitildiği için, aktivasyon işleminin verimli olması hesaplama süresinin kısaltılması ve sürenin kısaltılmasından dolayı elde edilecek maliyet optimizasyonu açısından önemlidir (Kumawat 2019).



5. TÜRLERİNE GÖRE AKTİVASTON FONKSİYONLARI

5.1 Basamak (Step) Fonksiyonu




Şekil 5.1 Basamak Fonksiyonu

Şekil 5.1’de Basamak (Step) fonksiyonu ikili değer alan bir fonksiyondur, dolayısıyla ikili sınıflayıcı olarak kullanılan türde bir fonksiyondur. Fonksiyonun türevi gizli katmanlarda öğrenme değeri temsil etmediğinden, tavsiye edilmez. Türevlenebilir bir fonksiyon olarak doğrusal(lineer) fonksiyon kullanılır (Kızrak 2019).

5.2 Doğrusal (Linear) Fonksiyon

Doğrusal Fonksiyon, Basamak fonksiyonundaki gibi ikili değerler üretmeyen bir fonksiyondur. Model geri yayılım üzerinden optimize edilmeye çalışılırken, doğrusal aktivasyon fonksiyonunun türevi sabit kalacağından dolayı, öğrenme işlemi yeteri kadar elde edilemez ve doğrusal olmayan aktivasyon fonksiyonları doğrusal fonksiyona göre derin öğrenme yöntemlerinde daha çok tercih edilir. Şekil 5.2’de Doğrusal fonksiyonun grafiği mevcuttur (Kızrak 2019).

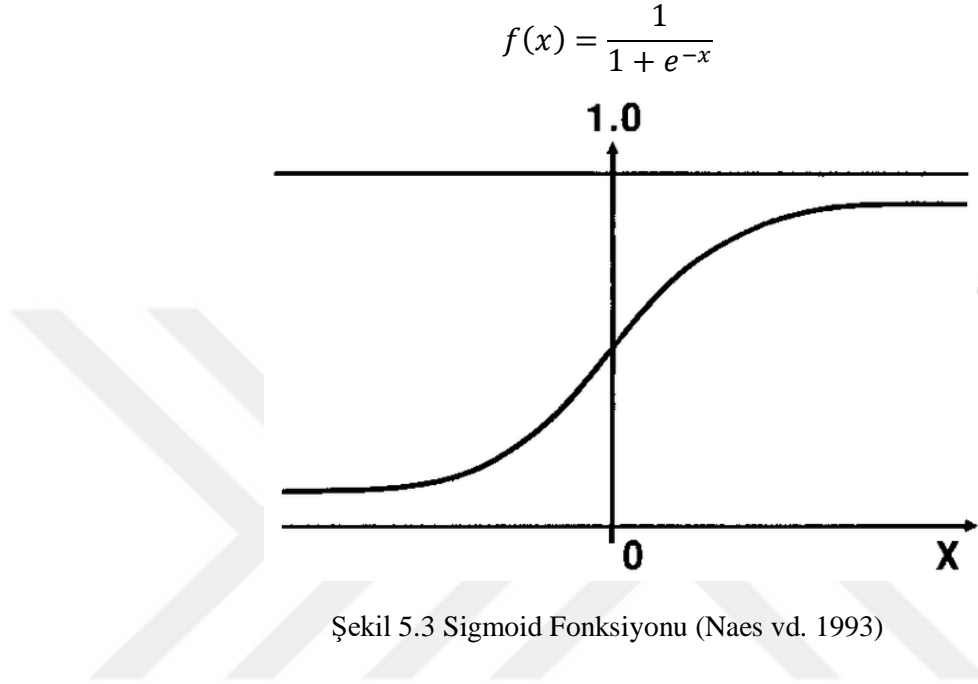


Şekil 5.2 Doğrusal Fonksiyon

5.3 Sigmoid Fonksiyonu

Sigmoid Fonksiyonu, derin öğrenme yöntemlerinde nöronlar arasındaki öğrenme sürecini en iyi şekilde sağlayabilmek için, genellikle geri yayılım algoritmasında kullanılır. Geri yayılım algoritmasının çalışma prensibi gereği, parametrelerin türevi alınır ve ağırlıkların güncelleme işlemi yapılarak devam edilir. Bu nedenle aktivasyon fonksiyonunun türevlenebilme özelliğine sahip olması son derece önemlidir. Doğrusal aktivasyon fonksiyonlarında geri yayılım algoritması kullanılırken türev alındığında yine sabit bir değer elde edilir. Bu sebepten ötürü, derin öğrenme yönteminde öğrenme işlemi gerçekleşemez. Bu sorunu ortadan kaldırmak ve algoritmanın öğrenebilmesini sağlayabilmek amacıyla, doğrusal olmayan aktivasyon fonksiyonu olan sigmoid fonksiyonu sürece dahil edilir. Sigmoid fonksiyonu, geri yayılım algoritmasında her bir düğüm için uygulandığında, uygulanan düğümün yapay sinir ağının hesaplama sürecine katkıda bulunup bulunmadığının anlaşılması için önemlidir. Bu katkı, gradyan iniş yöntemi kullanılırken, sigmoid fonksiyonunun türevinin gerekli ayarlamaların nasıl yapılacağına bilgisini vermesidir, çünkü bir fonksiyonun türevi fonksiyonun tanımlandığı grafiğin eğimini tanımlar. Bu eğim bize gradyan iniş yönteminde optimum


değeri yakalayabilmemiz, dolayısıyla maliyet fonksiyonunda minimum değere ulaşabilmemiz için çok önemlidir. Sigmoid fonksiyonunun grafiği ve matematiksel gösterimi Şekil 5.3'deki gibidir (Rasmussen 2016).



5.4 Hiperbolik Tanjant Fonksiyonu

Hiperbolik Tanjant Fonksiyonu, sigmoid fonksiyonuna benzerliği ile bilinen bir fonksiyondur. Hiperbolik Tanjant Fonksiyonunun sigmoid fonksiyonundan ayıran en temel özellik, $[-1,1]$ aralığın da tanımlanmış olmasıdır. Sigmoid fonksiyonuna göre avantajı ise, daha yüksek eğime sahip olduğu için, yani fonksiyon türevi daha dik olduğu için daha çok değer alabilmesidir. Bu durum, fonksiyonun öğrenme aşamasının sigmoid fonksiyona göre daha hızlı olmasına ve sınıflama işlemi yapıldığı durumda daha geniş bir sınıflama alanına sahip olmasını sağlamaktadır. Dezavantajı ise, uç değerlerde gradyan ölmesi problemi yaşamasıdır. Aşağıda Hiperbolik Tanjant Fonksiyonunun formülü ve grafiği Şekil 5.4'de görülmektedir (Kızrak 2019).

$$\tan(x) \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




Şekil 5.4 Hiperbolik Tanjant Fonksiyonu (Seidenberg 2000)

5.5 Düzeltilmiş Doğrusal Birim (Rectifier Linear Unit)

Düzeltilmiş Doğrusal Birim (Rectifier Linear Unit), kullanılan en yaygın aktivasyon fonksiyonlarından bir tanesidir. Düzeltilmiş Doğrusal Birim $[0, +\infty]$ arasında değer alan bir fonksiyondur. Düzeltilmiş Doğrusal Birim Fonksiyonunun, Sigmoid ve Hiperbolik tanjant fonksiyonlarına göre çok katmanlı yapay sinir ağlarında daha fazla tercih edilmesinin sebebi, hesaplama yükünün daha az olmasıdır. Çok katmanlı bir yapaya sinir ağında, sigmoid ve hiperbolik tanjant aktivasyon fonksiyonları tüm nöronların aynı şekilde aktive olmasını sağlar. Bu durum çok fazla işlem yükü getirir. Sinir ağındaki bazı nöronları aktif yapan ve daha seyrek bir aktivasyon durumu sağlayan, dolayısıyla daha az bir işlem yükü ile ağın aktivasyonunu sağlayabilen Düzeltilmiş Doğrusal Birim negatif eksende “0” değerini vermesi sebebiyle sinir ağının daha hızlı çalışabilmesini sağlamaktadır. İşlem hızı kazandırmasının sebebi, sıfır bölgesinin türevinin de sıfır olması, dolayısıyla öğrenmenin de bu bölgede gerçekleşiyor olmasıdır. Düzeltilmiş Doğrusal Birim Fonksiyonu ve formülü ve grafiği Şekil5.5’de yer almaktadır (Kızrak 2019).

$$f(x) = \max(0, x)$$



Şekil 5.5 Düzeltilmiş Doğrusal Birim (Relu) Fonksiyonu (Pauly vd. 2017)

Literatürde geçen diğer aktivasyon fonksiyonları ve fonksiyonların türev halleri aşağıdaki tabloda detaylı bir şekilde yer almaktadır.

6. TÜRLERİNE GÖRE OPTİMİZASYON FONKSİYONLARI VE KAYIP FONKSİYONU

6.1 Kayıp Fonksiyonu (Loss Function)

Bir sinir ağının ideal sonuçlara olan yakınlığını ölçen fonksiyona, kayıp fonksiyonu denir. Diğer bir deyişle, ölçülen tahmin değeri ile gerçek değer arasındaki mesafeyi ölçen ve mesafenin uzaklığına göre, sonucun ideal olup olmadığı bilgisini veren fonksiyondur. İdeal duruma ulaşma çabası, hatalardan kaynaklanan kaybı en aza indirecek parametreleri bulmakla eş değerdir. Bu parametreler, ağırlıklar ve yanlılık değerleri olarak adlandırılır. Gradyan iniş ve benzeri yinelemeli optimizasyon algoritmaları sayesinde, kayıp fonksiyonunun minimum değerine yaklaşmak mümkündür. Kayıp fonksiyonunun değerini minimum değerine yaklaştırmak için, birçok optimizasyon fonksiyonu mevcuttur. Gradyan İniş, Stokastik Gradyan İniş, Toplu Gradyan İniş, Momentum, AdaGrad, AdaDelta, RMSprop ve Adam fonksiyonları optimizasyon fonksiyonlarına örnek olarak verilebilir (Patterson ve Gibson 2017).

6.2 Gradyan İniş (Gradient Descent)

Gradyan iniş yönteminde tahmin değerlerimizin kalitesi, gerçek değere yakın olması ile ilgilidir. Tahminlerimizin kalitesini bir tablo olarak düşünürsek, bu tahminler ağırlıklara ve parametre değerlerine bağlı bir fonksiyon olarak alınır, tabloya uzaktan baktığımızda görüntü kalitesi düşecektir. Bu durum, gradyan düşüş yöntemindeki tepe değerlerin optimum değere olan uzaklığı ile birbirine benzer bir durumdur. Oysa ki, tepeden aşağı inişte optimum değere yaklaştıkça tahmin hatası azalacaktır ve tablo örneğindeki gibi optimum değerimize yaklaştıkça tablo netliği ve görüntü kalitesi artacaktır. Gradyan iniş algoritmasında, ağırlıklandırmalar güncellenerek algoritma tarafından eğimin yönü algılanır ve hedefe doğru ne kadar bir hızla iniş olacağına ise, öğrenme oranı (learning rate) ile karar verilir. İnişler adım adım ilerler ve sonunda optimum değere ulaşılır (Patterson ve Gibson 2017).

6.2.1 Toplu gradyan iniş (batch gradient descent)

Toplu gradyan iniş yöntemi, veri seti tüm eğitim örneklerini içerdiği durumlarda kullanılan bir gradyan yöntemidir. Her veri noktasına bir parametre güncellemesi uygulayan bir yöntemdir. Diğer bir deyişle, tek bir güncelleme yapmak için tüm veri kümesinin gradyanlarının hesaplanması gerektiğinden, toplu gradyan iniş yavaşlayabilir ve belleğe sığmayan veri kümeleri için zorlayıcı olabilir. Önceden belirlenen sayıda bir devir (epoch) boyunca, parametre vektörümüze göre tüm veri seti için kayıp fonksiyonunun gradyan vektörünü hesaplamak toplu gradyan iniş göstermenin bir yoludur (Alagözlü 2022).

6.2.2 Stokastik gradyan iniş (stochastic gradient descent)

Basit denetimli öğrenme ağında, her örnek rastgele bir girdi ve skaler bir çıktı değeri vermektedir. Tahmin maliyetini ölçen ve minimum değeri yakalanmak istenilen kayıp fonksiyonu ve bir ağırlık vektörü ile parametrelendirilebilen herhangi bir fonksiyon seçilir. Stokastik Gradyan İniş Yöntemi, her eğitim örneği için parametreleri güncelleyen bir yöntemdir. Süreç stokastik olması sebebiyle, her bir yineleme de rastgele örnekler seçilir. Bu durum, stokastik algoritmanın önceki yinelemeler sırasında hangi örnekleri görüntülediği ile ilgilenmez, dolayısıyla algoritma örnekleri tek bir geçişte işleyebilir ve hızlı bir şekilde çalışmasına ortam hazırlar. Diğer bir deyişle, stokastik gradyan iniş yöntemi, gradyan iniş yönteminde dezavantaj oluşturan kayıp fonksiyonunun türevinin hesaplanmasında kullanılan tüm veri setini kullanmak durumunda olmadığından, daha hızlı bir yöntem olma avantajını taşır (Alagözlü 2022).

6.3 Momentum Yöntemi

Stokastik gradyan iniş yönteminde optimum nokta aranırken oluşabilecek olan salınımın dezavantajını ortadan kaldırmak ve hedefe daha hızlı gidebilmek adına kullanılan bir yöntemdir. Kontrollü bir iniş sağlaması nedeniyle, stokastik gradyan inişin dezavantajına karşın önerilen bir yöntemdir (Seyyarer vd. 2020).

6.4 AdaGrad Yöntemi

Stokastik Gradyan iniş ve Momentum yöntemlerinin oluşturabileceği sabit öğrenme katsayısı problemine, her adımda farklı bir öğrenme katsayısı ile işlem yaparak çözüm getiren bir yöntemdir. Yöntem olarak ise, öğrenme katsayısını geçmiş gradyanların karelerinin kümülatif toplamının kareköküne bölmektedir (Seyyarer vd. 2020).

6.5 RMSprop Yöntemi

AdaGrad yöntemindeki gibi sabit öğrenme katsayısı problemine çözüm üretmek için önerilen bir yöntem olsa da, AdaGrad yöntemindeki gibi gradyan karelerini almak yerine momentumlu gradyan gradyanların karelerini almaktadır (Seyyarer vd. 2020).

6.6 AdaDelta Yöntemi

AdaDelta yönteminde, AdaGrad ve RMSprop yöntemlerinden farklı olarak öğrenme katsayısı seçme zorunluluğu ortadan kaldırılmıştır ve onun yerine geçerli ağırlıklar ile güncellenen ağırlıklar arasındaki farkın karelerinin momentumlu toplamları kullanılmıştır (Seyyarer vd. 2020).

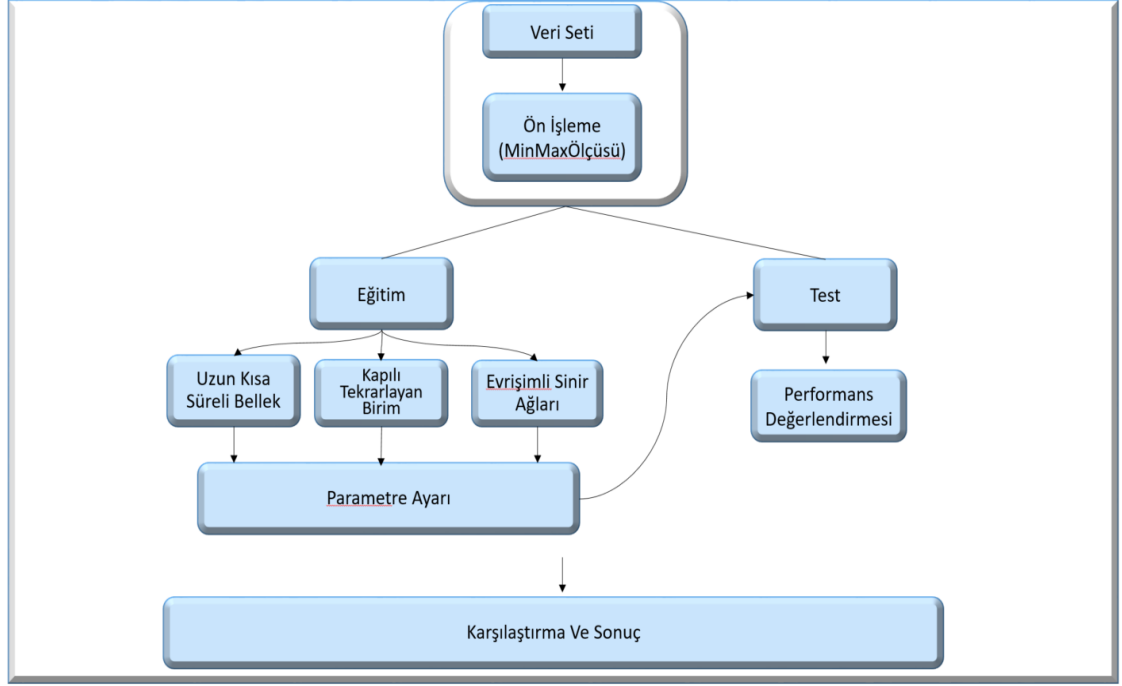
6.7 Adam Fonksiyonu (Adam Function)

RmSprop ve momentum yöntemlerinin etkili yönlerinin birleşiminden oluşan ve Toronto Üniversitesinde geliştirilmiş bir fonksiyondur. Gradyanların birinci ve ikinci anlarının tahminlerinden öğrenme oranlarını türeten bir optimizasyon yöntemidir (Seyyarer vd. 2020).

7. VERİ SETİ VE VERİ ANALİZİ

Üretilen rüzgar enerjisi tahmini için, gerçek zamanlı üretim verilerine ihtiyaç duyulmaktadır. Yapay Sinir Ağı algoritmalarını eğitmek ve doğru tahminler üretebilmek için, geçmişte doğru bir şekilde ölçülmüş rüzgar enerjisi üretim miktarlarına eğitim aşamasında ihtiyaç olmaktadır. Bu çalışmada kullanılan veriler, Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) rüzgar enerjisi üretim verileridir (Anonymous 2022b).

Veri setinde tarih, saat ve üretim miktarının megavat cinsinden rüzgar enerjisi için toplam sayısal değeri bulunmaktadır. Zaman aralığı olarak, 01.01.2015 tarihinden başlayarak 23.01.2022 tarihine kadarki yaklaşık 7 yıllık bir veri kümesi üzerinde analiz yapılmıştır. Veri seti, saatlik verileri içermekte olup 00:00 saatinden başlayarak, 1'er saat aralıklarla tüm günün verileri bulunmaktadır. Analiz aşamasında veriler saatlik verilerden günlük veriler olarak dönüştürülmüştür. Ölçülmüş saatlik veriler, toplamda 61917 satırlık bir veri setini oluşturmaktadır. Bu çalışmada uygulanan modelleri eğitmek için öğrenme oranı 0.001 ve devir boyutu(epoch) 100 olan bir Adam optimizer ile birlikte Keras kütüphanesi kullanılmıştır. Aktivasyon fonksiyonu olarak Relu fonksiyonu kullanılırken kayıp fonksiyonu (loss function) olarak Hata Kare Ortalaması (MSE) kullanılmıştır. Hesaplanan performans metrikleri, test setinde hesaplanmış olup, eğitilen test setinin algoritmada test boyutu (test size) 0.20 olarak seçilmiştir. Kullanılan dört modelinde performans metrikleri gecikme boyutu (lag size) ve düğüm sayıları (node size) değiştirilerek hesaplanmış ve tablolar halinde çalışmaya eklenmiştir. Gecikme olarak bahsedilen değer, zaman serisinde geçen sabit bir zaman dilimini ifade etmektedir. Gecikme boyutu ve düğüm sayısı hiper parametrelerinden, gecikme boyutu, 10 gün, 30 gün, 90 gün, 180 gün olarak ve sinir ağına eklenen düğüm sayıları da, 7, 14, 20, 40, 80, 100 olarak, en iyi performansı yakalamak adına çeşitli tüm kombinasyonlarla uygulanmıştır.



Şekil 7.1 Veri Setine uygulanan karar aşamaları (Ünlü 2022)

Tahmin süreci Şekil 7.1’de görüldüğü üzere 5 kısımdan oluşmaktadır. Yüksek sayısal değer veren değerler, yüksek ağırlık değerleri verebildiğinden, yüksek ağırlık değerleri genellikle kararsızdır. Bu durumda, yapay sinir ağının öğrenme kabiliyeti zayıflar ve girdi hassasiyetine sebep olur. Tüm bu durumlar daha büyük hata genellemesine sebep olur. Kararsızlık probleminin üstesinden gelebilmek için tüm veri seti, minimum-maksimum ölçekleyici dönüşümü yardımıyla dönüştürülür. X , gözlem değerini temsilen kullanılır ve X_{\min} veri setindeki en düşük değeri temsil ederken, X_{\max} veri setindeki en yüksek değeri temsil eder. Dönüşüm işleminin matematiksel formülasyonu şu şekildedir;

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

Dönüşüm işlemi gerçekleştirildikten sonra, veri seti Eğitim Veri Seti ve Test Veri Seti olmak üzere ikiye bölünür. Eğitim veri setinde algoritmadaki hiper parametrelere karar verilir ve test setindeki algoritma verilerin eğitimde kullanılmayan gözlemleri üzerinden

çalışmaktadır. Veri setinin yüzde 80'i eğitim verisinden oluşmakla birlikte, yüzde 20'si test verisinden oluşmaktadır. Eğitim veri setinde ikinci aşamaya gelindiğinde LSTM, BLSTM, GRU ve CNN algoritmaları eğitilmiştir. En yüksek performansın hangi algoritma türünden elde edebileceğini görebilmek adına farklı sayıda gecikme uzunluğu ve düğüm sayısı test edilmiştir. Uygulanan derin öğrenme yöntemleri, veri odaklı yöntemler oldukları için ayrı bir tasarımdan bahsedilemez. Her modelin optimizasyonu için Adam optimizer kullanılmış ve kayıp fonksiyonu olarak ise MSE kullanılmıştır. Bir sonraki aşamaya gelindiğinde ise, test setinde gecikme uzunlukları ve performansı en yüksek olan düğüm sayısı çalıştırılmıştır. Gecikme uzunluğu ve algoritmada yer alacak düğüm sayıları hiper parametrelerimizdir ve en uygun değerleri verecek şekilde deneme yanılma yoluyla sayısal değerleri belirlenmiştir. Bir sonraki aşamaya geçildiğinde ise, tahmin edilen değerler gözlenen aralığa geri dönüştürülmüştür. Son aşamaya gelindiğinde ise, kullanılan dört algoritmanın performanslarını karşılaştırmak amacıyla performans metrikleri hesaplanmıştır. Bu hesaplamayı yapmak için dört farklı performans ölçütü kullanılmıştır. Kullanılan performans ölçütleri sırasıyla MAE, MSE, RMSE ve R^2 . Her bir metrik için formüller aşağıdaki gibidir.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{f}_i)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{f}_i| = \frac{1}{n} \sum_{i=1}^n |e_i|$$

İlk formüldeki $SS_{res} = \sum_{i=1}^n (y_i - \hat{f}_i)^2 = \sum_{i=1}^n e_i^2$ artık kareler toplamını ifade ederken \hat{f}_i değeri ise tahmini çıktı değerini ifade etmektedir. Toplam kare toplamı $SS_{tot} = \sum_{i=1}^n (y_i - \bar{y})^2$ formülü ile ifade edilirken, gözlenen veri ortalaması \bar{y} sembolü ile ifade edilir. İyi bir performans elde edebilmek için küçük RMSE ve MAE değerlerine ihtiyaç duyulmaktadır. Ayrıca yine iyi bir uyum ve performans için R^2 nin aldığı değerlerin "1" e yakın olması beklenmektedir. LSTM algoritmasında (1,100) şeklinde LSTM katmanı ve (1,7) şeklinde yoğun (dense) katman uygulanmıştır. Yoğun katman,


tam bağlantılı katman olarak da isimlendirilir. Sinir ağındaki her bir nöronun, bir sonraki katmandaki tüm nöronlara bağlı olması durumudur (Patterson ve Gibson 2017).

LSTM algoritmasının her bir devri hesaplama süresi yaklaşık 3 saniye sürmüştür. Test setindeki farklı gecikme uzunlukları ve düğüm sayıları için performans metrikleri Çizelge 7.1’de gösterilmiştir. Çıkan sonuçlara göre, 90 gecikme boyutu ve 40 düğüm sayısı en iyi performansı vermektedir. Ölçülen performans metriğine göre R^2 değeri en yüksek değer olan, $R^2 = 0.4450$ değerini almış ve en düşük hata değerine sahip Hata Kare Ortalama değeri ise, $MSE = 0.0296$ değerini almıştır.




Çizelge 7.1 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre LSTM algoritması ile hesaplanan performans metrikleri

Gecikme Boyutu	Nod Sayısı	MAE	MSE	RMSE	R²
10	7	0.1400	0.0328	0.1813	0.3800
	14	0.1396	0.0310	0.1760	0.4153
	20	0.1379	0.0310	0.1761	0.4148
	40	0.1414	0.0325	0.1803	0.3869
	80	0.1382	0.0306	0.1749	0.4228
	100	0.1379	0.0308	0.1755	0.4187
30	7	0.1353	0.0299	0.1730	0.4365
	14	0.1414	0.0313	0.1770	0.4100
	20	0.1369	0.0297	0.1725	0.4400
	40	0.1421	0.0317	0.1781	0.4025
	80	0.1406	0.0302	0.1740	0.4300
	100	0.1461	0.0353	0.1879	0.3351
90	7	0.1362	0.0301	0.1736	0.4354
	14	0.1395	0.0303	0.1741	0.4319
	20	0.1355	0.0300	0.1734	0.4365
	40	0.1360	0.0296	0.1721	0.4450
	80	0.1472	0.0329	0.1815	0.3829
	100	0.1378	0.3088	0.1757	0.4216
180	7	0.1411	0.0323	0.1798	0.4002
	14	0.1378	0.0306	0.1749	0.4327
	20	0.1526	0.0366	0.1913	0.3211
	40	0.1659	0.0422	0.2055	0.2166
	80	-	-	-	-
	100	-	-	-	-



Şekil 7.2 LSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki

Şekil 7.2.'de ölçülen performans metriğine göre Düzeltilmiş R-kare değeri olan $R^2 = 0.4450$ değerini almış ve Hata Kare Ortalama değeri $MSE = 0.0296$ değerini almış, LSTM algoritmasının gerçek ve tahmin değerleri ilişkisi üzerinden oluşturulmuş grafik mevcuttur.




Şekil 7.3 LSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki

Şekil 7.3’de LSTM algoritmasının noktasal tahmin yeteneği görülmektedir. Ölçülen performans metriğine göre $R^2 = 0.4450$ değerini almış ve $MSE = 0.0296$ değerini almıştır. Sonuç olarak, LSTM algoritmasının gerçek ve tahmin değerleri arasındaki noktasal ilişkiye bakıldığında, LSTM algoritması kullandığımız veri seti üzerinde istenilen düzeyde tahmin yeteneğine sahip olmadığı görülmektedir.

BLSTM algoritmasında (1,100) şeklinde BLSTM katmanı ve (1,7) şeklinde yoğun katman uygulanmıştır. LSTM algoritmasının her bir devri hesaplama süresi yaklaşık 3 saniye sürmüştür. Test setindeki farklı gecikme uzunlukları ve düğüm sayıları için performans metrikleri Çizelge 7.2’de gösterilmiştir. Çıkan sonuçlara göre 180 gecikme boyutu ve 7 düğüm sayısı en iyi performansı vermektedir. Ölçülen performans metriğine göre en yüksek değer olan $R^2 = 0.4537$ değerini almış ve en düşük hata değerine sahip $MSE = 0.0294$ değerini almıştır.


Çizelge 7.2 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre BLSTM algoritması ile hesaplanan performans metrikleri

Gecikme Boyutu	Nod Sayısı	MAE	MSE	RMSE	R²
10	7	0.1380	0.0303	0.1742	0.4275
	14	0.1411	0.0318	0.1783	0.4001
	20	0.1406	0.0326	0.1808	0.3834
	40	0.1397	0.0316	0.1780	0.4025
	80	0.1363	0.0295	0.1719	0.4427
	100	0.1428	0.0333	0.1827	0.3706
30	7	0.1375	0.0292	0.1711	0.4489
	14	0.1420	0.0306	0.1750	0.4236
	20	0.1442	0.0316	0.1780	0.4035
	40	0.1488	0.0348	0.1867	0.3437
	80	0.1394	0.0302	0.1738	0.4310
	100	0.1498	0.0349	0.1868	0.3429
90	7	0.1863	0.0513	0.2265	0.0394
	14	0.1360	0.0296	0.1720	0.4457
	20	0.1378	0.0297	0.1724	0.4429
	40	0.1378	0.0293	0.1712	0.4509
	80	0.1377	0.0303	0.1742	0.4314
	100	0.1511	0.3484	0.1866	0.3475
180	7	0.1370	0.0294	0.1716	0.4537
	14	0.1592	0.0389	0.1972	0.2783
	20	0.1379	0.0306	0.1749	0.4327
	40	0.1365	0.0298	0.1727	0.4468
	80	0.1376	0.0308	0.1757	0.4273
	100	-	-	-	-



Şekil 7.4 BLSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki

Şekil 7.4’de görüldüğü üzere ölçülen performans metriğine göre $R^2 = 0.4537$ değerini almış ve $MSE = 0.0294$ değerini. Tahmin değerlerinin, gözlem değeri doğrusu üzerinde noktasal olarak yeterli bir şekilde kümelenemediği görülmektedir. Oluşan bu durum, Düzeltilmiş R-kare değerinin “1” ‘e yakın bir değer olmadığını ve BLSTM algoritmasının kullandığımız veri seti üzerinde yeterli bir performansı olmadığını göstermektedir.



Şekil 7.5 BLSTM modelinin gerçek değer ve tahmin değerleri arasındaki ilişki

Şekil 7.5’de BLSTM algoritmasının noktasal tahmin yeteneği görülmektedir. Ölçülen performans metriğine göre, $R^2 = 0.4537$ değerini almış ve $MSE = 0.0294$ değerini almıştır. BLSTM algoritmasının gerçek ve tahmin değerleri arasındaki noktasal ilişkisi üzerinden görüldüğü üzere, BLSTM algoritması kullandığımız veri seti üzerinde istenilen düzeyde tahmin yeteneğine sahip değildir.

GRU algoritmasında (1,100) şeklinde GRU katmanı ve (1,7) şeklinde yoğun katman uygulanmıştır. GRU’nun her bir devri hesaplama süresi yaklaşık 3 saniye sürmüştür. Test setindeki farklı gecikme uzunlukları ve düğüm sayıları için performans metrikleri Çizelge 7.3’de gösterilmiştir. Çıkan sonuçlara göre, 180 gecikme boyutu ve 7 düğüm sayısı en iyi performansı vermektedir. Ölçülen performans metriğine göre en yüksek değer olan $R^2 = 0.4592$ değerini almış ve en düşük hata değerine sahip $MSE = 0.0291$ değerini almıştır.

Çizelge 7.3 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre GRU algoritması ile hesaplanan performans metrikleri


Gecikme Boyutu	Nod Sayısı	MAE	MSE	RMSE	R²
10	7	0.1383	0.0303	0.1743	0.4271
	14	0.1387	0.0311	0.1764	0.4132
	20	0.1380	0.0302	0.1739	0.4293
	40	0.1380	0.0304	0.1743	0.4265
	80	0.1408	0.0324	0.1800	0.3888
	100	0.1398	0.0320	0.1791	0.3948
30	7	0.1381	0.0302	0.1738	0.4312
	14	0.1369	0.0296	0.1720	0.4428
	20	0.1385	0.0301	0.1735	0.4333
	40	0.1390	0.0311	0.1765	0.4133
	80	0.1383	0.0307	0.1753	0.4213
	100	0.1423	0.0329	0.1816	0.3792
90	7	0.1365	0.0290	0.1704	0.4562
	14	0.1359	0.0297	0.1726	0.4421
	20	0.1370	0.0301	0.1736	0.4353
	40	0.1371	0.0301	0.1737	0.4348
	80	0.1378	0.0302	0.1738	0.4338
	100	0.1378	0.3088	0.1757	0.4216
180	7	0.1361	0.0291	0.1707	0.4592
	14	0.1361	0.0292	0.1709	0.4581
	20	0.1364	0.0295	0.1720	0.4513
	40	0.1377	0.0304	0.1745	0.4349
	80	0.1372	0.0298	0.1728	0.4461
	100	0.1380	0.0309	0.1760	0.4253

Çizelge 7.4 Test setinde değişik gecikme boyutuna ve düğüm sayılarına göre CNN algoritması ile hesaplanan performans metrikleri

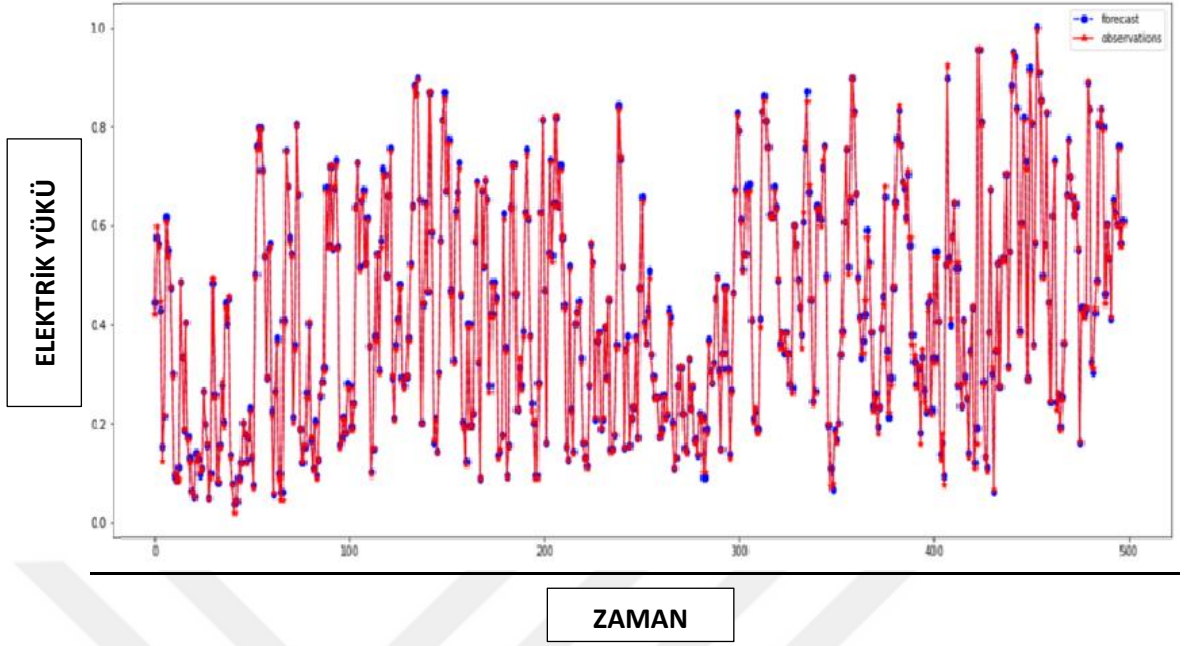
Gecikme Boyutu	Nod Sayısı	MAE	MSE	RMSE	R²
10	7	0.1330	0.0282	0.1679	0.4679
	14	0.1333	0.0278	0.1669	0.4748
	20	0.1339	0.0267	0.1634	0.4961
	40	0.1325	0.0264	0.1625	0.5017
	80	0.1242	0.0235	0.1534	0.5558
	100	0.1189	0.0226	0.1504	0.5734
30	7	0.1177	0.0219	0.1482	0.5864
	14	0.1193	0.2156	0.1468	0.5942
	20	0.1129	0.0193	0.1389	0.6366
	40	0.0722	0.0084	0.0919	0.8410
	80	0.0754	0.0087	0.0937	0.8344
	100	0.0590	0.0057	0.0755	0.8924
90	7	0.0970	0.0152	0.1236	0.7138
	14	0.0879	0.0119	0.1092	0.7764
	20	0.0519	0.0044	0.0665	0.9170
	40	0.0351	0.0019	0.0442	0.9634
	80	0.0160	0.0004	0.0204	0.9921
	100	0.0063	0.0001	0.0083	0.9986
180	7	0.0425	0.0030	0.0552	0.9434
	14	0.0319	0.0016	0.0400	0.9703
	20	0.0152	0.0003	0.0186	0.9935
	40	0.0142	0.0003	0.0181	0.9938
	80	0.0370	0.0022	0.0476	0.9578
	100	0.0234	0.0007	0.0275	0.9858

CNN algoritmasında evrişim katmanı boyutu (Yok, 1,64) şeklinde, MaxPooling katmanı boyutu (Yok, 1,64) ve düz boyut katmanı (flatten layer of size) ise (Yok, 64) olarak ayarlanmıştır. Ayrıca, yoğun katmanı (Yok, 100) ve (Yok, 7) olarak uygulanmıştır. CNN'in her bir devri hesaplama süresi yaklaşık 3 saniye sürmüştür. Test setindeki farklı gecikme uzunlukları ve düğüm sayıları için performans metrikleri Çizelge 7.4'de gösterilmiştir. Çıkan sonuçlara göre 90 gecikme boyutu ve 100 düğüm sayısı en iyi performansı vermektedir. Ölçülen performans metriğine göre en yüksek değer olan $R^2 = 0.9986$ değerini almış ve en düşük hata değerine sahip $MSE = 0.0001$ değerini almıştır.

Şekil 7.6'da, ölçülen performans metriğine göre, CNN algoritmasının gerçek ve tahmin değerleri ilişkisi üzerinden oluşturulmuş grafik mevcuttur. Tahmin değerlerinin, gözlem değeri doğrusu üzerinde noktasal olarak yeterli bir şekilde kümелendiği görülmektedir. Oluşan bu durum düzeltilmiş R-kare değerinin "1" 'e çok yakın bir değer olduğunu ve CNN algoritmasının kullandığımız veri seti üzerinde en iyi performansı gösteren yöntem olduğunu açıkça göstermektedir.



Şekil 7.6 CNN modelinin gerçek deęer ve tahmin deęerleri arasındaki ilişki



Şekil 7.7 CNN modelinin gerçek değer ve tahmin değerleri arasındaki ilişki

Şekil 7.7’de Evrişimli Sinir Ağı (CNN) algoritmasının noktasal tahmin yeteneği verilmiştir. CNN algoritmasının gerçek ve tahmin değerleri arasındaki noktasal ilişkisi üzerinden görüldüğü üzere CNN algoritması kullandığımız veri seti üzerinde ileri düzeyde tahmin yeteneğine sahiptir.

Kullanılan dört model arasında en yüksek doğrulukta tahminleri veren ve en düşük hata kare ortalama değerine sahip olan algoritma CNN algoritmasıdır. Dört modelin ölçülen performans metrikleri karşılaştırması Çizelge 7.5’de verilmiştir.

Çizelge 7.5 Algoritmaların performans metrikleri üzerinden karşılaştırılması

Algoritma	MAE	MSE	RMSE	R2
Kısa Uzun Süreli Bellek (LSTM)	0.1360	0.0296	0.1721	0.4450
İki Yönlü Kısa Uzun Süreli Bellek (BLSTM)	0.1370	0.0294	0.1716	0.4537
Kapılı Tekrarlayan Birim (GRU)	0.1361	0.0291	0.1707	0.4592
Evrişimli Sinir Ağı (CNN)	0.0063	0.0001	0.0083	0.9986

8. SONUÇ VE ÖNERİLER

Elektrik enerjisi, sanayiden evlere, her türlü alanda kullanılan ve bir ülkenin sosyo-ekonomik gelişmişliği ile doğru orantılı bir şekilde üretilen ve tüketilen bir enerjidir. Elektrik, insanlığın gelişmesi için çok büyük bir adım olmuştur ve teknolojinin hızla ilerlediği günümüzde çok değerli bir araçtır. Fakat değişen ve gelişen dünya coğrafyasında hızla artan dünya nüfusu ve sanayi ve teknolojinin hızla gelişmesi ile elektrik tüketiminde son yıllarda büyük artışlar olmuştur. Hızla artan tüketim miktarlarını karşılamak için,, tüm dünya da elektrik enerjisi üretimi için kullanılan üretim kaynakları da yine hızlı bir şekilde tüketilmektedir. Yalnızca hızlı tüketimi sebebiyle oluşan kaynak eksikliği değil, aynı zamanda çevre dostu olmayan elektrik enerjisi üretim yöntemleri de ekosisteme büyük zarar vermektedir. Oluşan çevre kirliliği ve karbon salınımından doğan iklim değişiklikleri nedeniyle, yenilenebilir ve çevre dostu olan enerji üretim yöntemlerine olan yönelimler zamanla artmaya başlamıştır. Geline son nokta da, yenilenebilir enerji kaynaklarına yatırım yapan ülke sayısı artmıştır. Türkiye’de yenilenebilir enerji kaynaklarına yatırımı artıran ülkeler arasında yer almaktadır. Özellikle coğrafi avantajları sayesinde rüzgar enerjisi üretim potansiyeli yüksek olan ülkemizde, son dönemlerde rüzgar enerjisinden faydalanmak adına rüzgar türbinleri, hatta rüzgar çiftlikleri kurulmaktadır. Üretim ve dağıtım planlaması yapılması adına, rüzgar enerjisi üretimi ve dağıtımında doğru projeksiyonların oluşturulması ve uygulanması büyük önem taşımaktadır. Etkin bir enerji üretim planlaması yapılabilmesi için, doğru enerji talebi tahminleri, karar vericiler ve enerji üretimi ve dağıtımını yapan firmalar adına hayati önem taşımaktadır. Enerji yükünün tahmini için geçmişte birbirinden farklı yaklaşımlar araştırılmıştır. Bu çalışmada kullanılan veri seti, elektrik taleplerini optimum şekilde karşılamak ve enerji üretim politikalarını doğru şekillendirmek adına, Türkiye’deki üretilen günlük enerji üretimi verilerinden oluşmaktadır.

Metodolojinin tahmin kabiliyeti, klasik zaman serisi analizinde gösterilmiş olmasına rağmen, durağanlık varsayımı gibi belirli dezavantajlara sahiptir. Diğer derin öğrenme ve makine öğrenmesi algoritmalarından farklı olarak Box-Jenkins tipi zaman serisi modelleri doğrusal zaman serisi modelleridir. ARIMA tipi modelleri diğer modellerle karşılaştıran literatürde yeterli sayıda çalışma bulunmaktadır. Bu çalışmalara örnek

olarak harmonik regresyonun, otoregresif modelden daha güçlü olduğunu Akdi ve arkadaşları yaptıkları çalışmada göstermişlerdir (Akdi vd. 2020).

Tokgöz ve Ünal ise 2018 yılında yaptıkları bir çalışmada ARIMA modelini derin öğrenme yöntemlerinden sinir ağları ile karşılaştırmış ve ARIMA modelinin en düşük Ortalama Mutlak Hata Yüzdesi (MAPE) değerine sahip olduğunu göstermişlerdir (Tokgöz ve Ünal 2018).

Bu çalışmada Box-Jenkins modelini kullanmak yerine özelleştirilmiş bir derin öğrenme algoritması kullanılmıştır. Önerilen modelde, model durağanlığı veya modelin dağılımının normal dağılım olması veya ilişkisiz artık terim varsayımlarına sahip olup olmadığına bakılmaksızın hesaplamalar yapılmıştır. Bu özelliğiyle birlikte, modelin güçlü bir model olduğu görüşü daha da kuvvetlenmiştir.

Önerilen modelin gücü tek değişkenli bir yapıya sahip olmasına rağmen, elektrik talebi ve meteorolojik parametreler arasındaki ilişkileri araştırmak isteyen ilerideki araştırmalar, derin öğrenme algoritmaları sayesinde mümkün olabilecektir. İleride yapılacak araştırmalar için, elektrik üretimi tahmininde zaman serisi yaklaşımları ve derin öğrenme modellerinin kombinasyonları birlikte kullanılabilir ve hibrit modeller oluşturulabilir. Hibrit modellere örnek olarak, Stefenon ve arkadaşlarının dalgacık dönüşümünün etkilerini araştırdığı model gösterilebilir (Stefenon vd. 2020).

Türkiye'deki güç taleplerinin tahmini için, hem çok değişkenli hem de tek değişkenli bağlamda kullanılabilen hibrit yaklaşımları incelemek de mümkündür. Bu bağlamda Akbal ve Ünlü'nün 2021 yılında Ankara'da gerçekleştirdiği çalışma örnek olarak yeni araştırmacılara önerilebilir (Akbal ve Ünlü 2021).

Bu çalışmadaki temel amaç, Türkiye'deki elektrik yükünün günlük tahminin tek değişkenli bir derin öğrenme modeli ile etkin bir şekilde tahminidir. LSTM, BLSTM, GRU ve CNN modelleri 7 yıllık günlük ve saatlik enerji yüklerini içeren veri setine uygulanmış ve sonuç olarak Evrişimsel Sinir Ağı modelinin en iyi tahmin performansı gösteren model olduğuna karar verilmiştir. Evrişimsel Sinir Ağı modeli, dışındaki uygulanan üç modelde de birbirine yakın performans değerleri ölçülmüştür. Performans

değerlerine bakılırken, tablolar halinde gösterilen belirli performans metriklerine bakılmıştır. Sonuç olarak, bu çalışma uygun gecikme miktarı ve düğüm sayısı belirlendiği takdirde CNN modelinin günlük enerji üretimi tahminini çok başarılı bir şekilde gerçekleştirdiğini göstermiştir.

Bu sonuçlar ışığında, bu çalışmanın metodolojisinin bulguları, günümüz dünyasında elektrik piyasalarına matematiksel modeller sayesinde nasıl müdahale edilebileceği ve gerekli düzenlemelerin yapılabilmesi adına, bilimsel kanıtlar ve öneriler sunmaktadır.



KAYNAKÇA

- Aggarwal, C. 2018. Neural Networks and Deep Learning_ A Textbook. Springer, 493, USA
- Akbal, Y. ve Ünlü, K.D. 2021. A deep learning approach to model daily particular matter of Ankara: Key features and forecasting. Int. J. Environ. Sci. Technol. 1–17.
- Akdi, Y., Gölveren, E., ve Okkaoğlu, Y. 2020. Daily electrical energy consumption: Periodicity, harmonic regression method and forecasting. Energy, 191, 116524.
- Alagözülü, M. 2022. Stochastic Gradient Descent Variants and Applications.
- Anonim. 2018. Web Sitesi: https://tr.wikipedia.org/wiki/Otoregresif_hareketli_ortalamalar_modeli, Erişim Tarihi 22.06.2022
- Anonim. 2021. Web Sitesi: https://tr.wikipedia.org/wiki/İnsan_beyni, Erişim Tarihi: 14.06.2022
- Anonim. 2022. Web Sitesi: <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik>, Erişim Tarihi: 20.06.2022
- Anonymous. 2018a. Web Sitesi: <https://ekolojist.net/ruzgar-enerjisinden-elektrik-uretimi/>, Erişim Tarihi: 15.06.2022
- Anonymous. 2018b. Web Sitesi: <https://www.superdatascience.com/blogs/the-ultimate-guide-to-convolutional-neural-networks-cnn>, Erişim Tarihi: 07.06.2022
- Anonymous. 2020a. Web Sitesi: <https://www.ibm.com/cloud/learn/neural-networks>, Erişim Tarihi 14.06.2022
- Anonymous. 2020b. Web Sitesi: <https://www.superdatascience.com/blogs/the-ultimate-guide-to-recurrent-neural-networks-rnn>, Erişim Tarihi: 10.06.2022
- Anonymous. 2021a. Web Sitesi: <https://www.dailysabah.com/business/energy/izmir-turkeys-potential-capital-in-offshore-wind-energy>, Erişim Tarihi: 08.06.2022
- Anonymous. 2022a. Web Sitesi: <https://www.enerjiatlası.com/ruzgar/>, Erişim Tarihi: 20.06.2022
- Anonymous. 2022b. Web Sitesi: <https://seffaflik.epias.com.tr/transparency/uretim/gercek-zamanli-uretim.xhtml#>, Erişim Tarihi: 01.03.2022
- Bajwa, A. 2022. Web Sitesi: <https://www.educative.io/answers/what-are-the-types-of-rnn>, Erişim Tarihi: 18.06.2022
- Burton, T., Jenkins, N., Bossanyi, E., Sharpe, D., ve Graham, M. 2021. Wind Energy Handbook. Wiley, 1008, USA
- Cantürk, S. 2018. Bir Rüzgar Çiftliğinden Yapay Sinir Ağlarıyla Kısa Süreli Elektrik Üretim Tahmini. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Temiz-Tükenmez Enerjiler Anabilim Dalı, 112, Ankara

- Catalao, J., Pousinho H.M.I., ve Mendes, V.M.F. 2009. An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal. *Engineering Intelligent Systems*, 1-5.
- Celik, A. ve Kolhe, M. 2013. Generalized feed-forward based method for wind energy prediction, *Applied Energy*, 101, 582-588
- Chang, W. 2014. A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, 2, 161-168
- Dhiman, H.S. ve Deb, D. 2020. A Review of Wind Speed and Wind Power Forecasting Techniques. *ArXiv*, abs/2009.02279.
- Durdyev, S., 2010. Rüzgar Enerjisinde Uygun Türbin Seçimi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı, 71s, İstanbul.
- Elibüyük, U. ve Üçgül, İ. 2014. Rüzgâr Türbinleri, Çeşitleri Ve Rüzgâr Enerjisi Depolama Yöntemleri. *Yekarum e-Dergi*, 2(3)
- Eseye, A., Zhang, J., Zheng, D., ve Shiferaw, D. 2016. Short-Term Wind Power Forecasting Using Artificial Neural Networks for Resource Scheduling in Microgrids. *International Journal of Science and Engineering Applications*. 5. 144-151
- Fazelpour, F., Tarashkar, N., ve Rosen, M.A. 2016. Short-term wind speed forecasting using artificial neural networks for Tehran, Iran. *International Journal of Energy and Environmental Engineering*, 7(4), 377-390
- Fountas, Z. 2022. Imperial College Spiking Neural Networks for Human-like Avatar Control in a Simulated Environment, London
- Frizzo S., Kasburg, C., Nied, A., Rodrigues-Klaar, A. C., Silva-Ferreira, F. C., ve Waldrigues-Branco, N. 2020. Hybrid deep learning for power generation forecasting in active solar trackers. *IET Generation, Transmission & Distribution*, 14(23), 5667-5674
- Hamzaçebi, C., Es, H. A., ve Çakmak, R. 2019. Forecasting of Turkey's monthly electricity demand by seasonal artificial neural network. *Neural Computing and Applications*, 31(7), 2217-2231
- Hau, E. 2010. *Wind Turbines: Fundamentals, Technologies, Application, Economics*. Springer, 783, Heidelberg
- Hochreiter, S. (1998). The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6, 107-116.
- Exist. 2022. Web Sitesi: <https://seffaflik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml#>, Erişim Tarihi: 04.05.2022
- İlkılıç, Z. 2016. Türkiye’de Rüzgar Enerjisi ve Rüzgar Enerji Sistemlerinin Gelişimi. *Batman Üniversitesi Yaşam Bilimleri Dergisi*, 6(2)
- Kara, B. 2019. Web Sitesi: <https://medium.com/@buse.kara7998/perceptron-nedir>, Erişim Tarihi: 01.05.2022

- Karık, F., Sözen, A., ve İzgeç, M.M. 2017. Rüzgâr gücü tahminlerinin önemi: Türkiye elektrik piyasasında bir uygulama. *Politeknik Dergisi*, 20(4), 851-861
- Kariniotakis, G., Nogaret, E., ve Stavrakakis G. 1997. “Advanced Short-Term Forecasting of Wind Power Production,” in *Proceedings of the European Wind Energy Conference EWEC’97*, , 751–754, Dublin, Ireland.
- Kızra, A. 2019. Web Sitesi: <https://ayyucekizrak.medium.com/derin-öğrenme-için-aktivasyon-fonksiyonlarının-karşılaştırılması-cee17fd1d9cd>, Erişim Tarihi: 02.05.2022
- Kirbas, I. ve Kerem, A. 2016. Short-term wind speed prediction based on artificial neural network models. *Measurement and Control*, 49(6), 183-190
- Kolhe, M., Lin T., ve Maunuksela, J. 2011. GA-ANN for short-term wind energy prediction. *Asia-Pacific Power and Energy Engineering Conference, APPEEC*.
- Kumawat, D. 2019. Web Sitesi: <https://www.analyticssteps.com/blogs/7-types-activation-functions-neural-network>, Erişim Tarihi: 07.04.2022
- Liu, H., Tian, H.Q., Chen, C., ve Li, Y.F. 2010. A hybrid statistical method to predict wind speed and wind power. *Renewable energy*, 35(8), 1857-1861
- Lipton, Z. 2015. *A Critical Review of Recurrent Neural Networks for Sequence Learning*.
- Mijwil, M. 2017. *Yapay Sinir Ağlar Yapısı ve Fonksiyonu*.
- Musgrove, P. 2010. *Wind Power*. Cambridge University Press, 338, Cambridge
- Næs, T., Kvaal, K., Isaksson, T., ve Miller, C. 1993. Artificial Neural Networks in Multivariate Calibration. *Journal of Near Infrared Spectroscopy - J NEAR INFRARED SPECTROSC*. 1. 10.1255/jnirs.1.
- Nalcaci, G., Özmen, A., ve Weber, G.W. 2019. Long-term load forecasting: models based on MARS, ANN and LR methods. *Central European Journal of Operations Research*, 27(4), 1033-1049
- Newitz, A. 2021. Web Sitesi: <https://arstechnica.com/gaming/2021/05/an-ai-wrote-this-movie-and-its-strangely-moving/>, Erişim Tarihi: 07.05.2022
- Öztürk, A. ve Taspınar, F. 2019. Short term load forecasting for Turkey energy distribution system with artificial neural networks. *Tehnicki Vjesnik*, 26, 1545–1553
- Patterson, J. ve Gibson, A. 2017 *Deep Learning: A Practitioner’s Approach*. O’Reilly Media, Inc., Sebastopol.
- Pauly, L., Peel, H., Luo, S., Hogg, D., ve Fuentes, R. 2017. Deeper Networks for Pavement Crack Detection. 10.22260/ISARC2017/0066.
- Peng, H., Liu, F., ve Yang, X. 2013. A hybrid strategy of short term wind power prediction. *Renewable Energy*, 50, 590-595
- Putnam, G.C. 1948. *Power from the Wind*. Van Nostrand Reinhold, 225, New York
- Ramírez-Rosado I.J. ve Fernández-Jiménez L.A. 2003. “Next-day wind farm electric energy generation forecasting using fuzzy time-series,” in *Proceedings*

- International Conference on Modeling, Identification and Control, 237–240, Innsbruck, Austria
- Rasmussen, J. 2016. Web Sitesi: <https://towardsdatascience.com/understanding-the-derivative-of-the-sigmoid-function-cbfd46fb3716>, Eriřim Tarihi: 02.04.2022
- Sarioöz, Ü. 2022. Web Sitesi: <https://www.umitsarioz.com/post/yapay-sinir-ađları-ve-derin-öđrenme-genel-bakiř>, Eriřim Tarihi: 04.05.2022
- Selin, N. 2021. Web Sitesi: <https://www.britannica.com/science/wind-power>, Eriřim Tarihi: 04.03.2022
- Serrano-González, J. ve Lacal-Arántegui, R. 2016. Technological evolution of onshore wind turbines – a market-based analysis. *Wind Energy*, 19(12), 2171–2187
- Seidenberg, M. 2000. Phonology, Reading Acquisition, and Dyslexia: Insights from Connectionist Models. *Psychological Review*. 106. 10.1037//0033-295X.106.3.491.
- Seyyarer, E., Ayata, F., Uçkan, T., ve Karcı, A. 2020. Applications and Comparison of Optimization Algorithms used in Deep Learning Anatolian Science, 5(2), 90-98
- Shimpi, T. 2019. Web Sitesi: <https://medium.com/@tanmayshimpi/difference-between-ml-and-deep-learning-with-respect-to-splitting-of-the-dataset-into-375d433ee2c8>, Eriřim Tarihi: 04.05.2022
- Soman, S., Zareipour, H., Malik, O.P., ve Mandal, P. 2010. A review of wind power and wind speed forecasting methods with different time horizons. *North American Power Symposium 2010, NAPS 2010*. 1- 8. 10.1109/NAPS.2010.5619586
- SuperDataScience Team 2018. Web Sitesi: <https://www.superdatascience.com/blogs/the-ultimate-guide-to-artificial-neural-networks-ann>, Eriřim Tarihi: 10.04.2022
- TEİAŞ. 2020. Web Sitesi: <https://www.teias.gov.tr/tr-TR/turkiye-elektrik-uretim-iletim-istatistikleri>, Eriřim Tarihi: 04.06.2022
- Tokgöz, A. ve Ünal, G. 2018. A RNN based time series approach for forecasting Turkish electricity load. In *Proceedings of the 2018 26th Signal Processing and Communications Applications Conference (SIU)*, Izmir, Turkey
- Ünlü, K.D. 2022. A Data-Driven Model to Forecast Multi-Step Ahead Time Series of Turkish Daily Electricity Load. *Electronics*, 11, 1524.
- Verma, Y. 2021. Web Sitesi: <https://analyticsindiamag.com/complete-guide-to-bidirectional-lstm-with-python-codes/>, Eriřim Tarihi: 03.05.2022
- Yukseltan, E., Yucekaya, A., Bilge, A. H. 2017. Forecasting electricity demand for Turkey: Modeling periodic variations and demand segregation. *Applied Energy*, 193, 287-296
- Zafeirios, F. 2022. Spiking Neural Networks for Human-like Avatar Control in a Simulated Environment. Yüksek Lisans Tezi, Imperial College London, Computing Science, 60, London