

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ SİSTEMLERİ ANABİLİM DALI**

**KAYSERİ İLİ İÇİN GÜNEŞ SANTRALİ ELEKTRİK
ENERJİSİ ÜRETİM TAHMİN PLANLAMASI**

**Hazırlayan
Obed NKURIYINGOMA**

**Danışman
Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU**

Yüksek Lisans Tezi

**Eylül 2018
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ SİSTEMLERİ ANABİLİM DALI**

**KAYSERİ İLİ İÇİN GÜNEŞ SANTRALİ ELEKTRİK
ENERJİSİ ÜRETİM TAHMİN PLANLAMASI**

(Yüksek Lisans Tezi)

**Hazırlayan
Obed NKURIYINGOMA**

**Danışman
Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU**

**Eylül 2018
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Obed Nkuriyngoma



“Kayseri İli İçin Güneş Santrali Elektrik Enerjisi Üretim Tahmin Planlaması” adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Hazırlayan

Obed NKURIYINGOMA



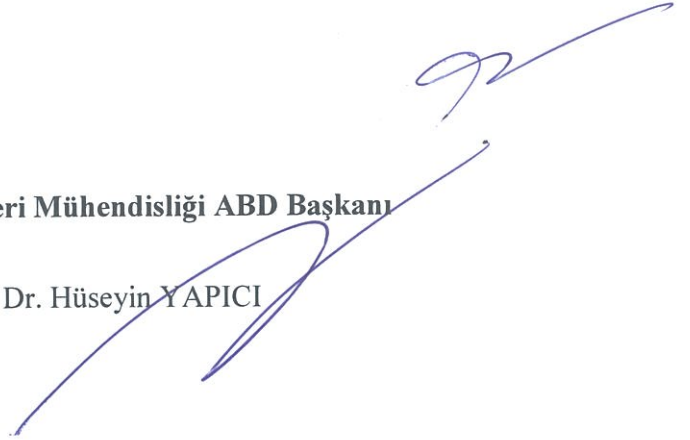
Danışman

Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU



Enerji Sistemleri Mühendisliği ABD Başkanı

Prof. Dr. Hüseyin YAPICI



Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU danışmanlığında Obed NKURIYINGOMA tarafından hazırlanan “**Kayseri İli İçin Güneş Santrali Elektrik Enerjisi Üretim Tahmin Planlaması**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Enerji Sistemleri Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

10. / 09 / 2018

JÜRİ:

Danışman : Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU

Üye : Prof. Dr. Hüseyin YAPICI

Üye : Prof. Dr. Hilmi Cenk Bayrakçı

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 14/09/2018 tarih ve 2018/43-14...sayılı kararı ile onaylanmıştır.



14 / 09 / 2018
Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

TEŐEKKÜR

Bana alıŐmalarım süresince her türlü yardımı ve fedakârlığı sađlayan, Dr. Öğr. Üyesi Saltuk Buđra SELÇUKLU'ya en büyük teşekkürü sunmak istiyorum. Onun rehberlik ve teşviđi olmadan, bu tez gerçekleşemezdi. Fikirlerinin açık paylaşımı, ön görüşü ve esnekliđi benim için çok deđerliydi.

Obed NKURIYINGOMA

Eylül 2018, KAYSERİ



KAYSERİ İLİ İÇİN GÜNEŞ SANTRALİ ELEKTRİK ENERJİSİ ÜRETİM TAHMİN PLANLAMASI

Obed NKURIYINGOMA

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Eylül 2018
Danışman: Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU

ÖZET

Genel olarak dünya nüfusunun artması ve altyapının gelişmesi nedeniyle enerji ihtiyacı her geçen gün artmaktadır. Enerji üretimi sektörü için geleneksel enerji kaynaklarının sınırlandırılması bir zorluk getirmektedir. Bu nedenle yenilenebilir enerji kaynaklarından enerji üretmek için bazı teknolojiler geliştirilmiştir. Ancak, doğal olarak aralıklı olan, hava durumuna bağlı ve planlanmamış yenilenebilir enerji kaynaklarının güç çıktısını tahmin etmek bir bilimsel ve toplumsal kaygı haline gelmiştir. Bu tezde, fotovoltaik (PV) sistemlerin kısa ve orta vadeli tahminlerini sağlamak için bir sinir ağı modeli geliştirilmeye çalışılmıştır. Meteoroloji istasyonundan, geçmiş hava durumu verilerini kullanarak, lineer olmayan PV sistem çıkış gücünü tahmin etmek için bir Doğrusal Olmayan Özbağlanımlı Dış Girdili Ağ Modeli (Non-linear AutoRegressive network with eXogenous input, NARX) kurulmuştur. Daha sonra, modelin performansı PV sisteminin tahmini gücü için farklı istatistiksel değerlendirme parametreleri kullanılarak analiz edilmiştir. Bu çalışma ile PV sisteminin güç çıkışı tahmin yönteminin Türkiye’de Kayseri ilinde başarıyla kullanılabileceğini ve diğer bölgelerde de uygulanabileceğini göstermiştir. Bu çalışma, Türkiye’deki güneş enerjisi şirketlerinin yararınadır ve akademik amaçlar için de kullanılabilir.

Anahtar Kelimeler: Güneş Enerjisi, PV, Enerji Üretim Tahmini, Yapay Sinir Ağı, NARX Modeli

SOLAR POWER PLANT ELECTRICITY GENERATION FORECASTING PLANNING: A CASE STUDY IN KAYSERI

Obed NKURIYINGOMA

Erciyes University, Graduate School of Natural and Applied Sciences

Master Thesis, September 2018

Supervisor: Asst. Prof. Saltuk Buğra SELÇUKLU

ABSTRACT

The energy need increases day by day due to the development of infrastructure and the increase in the population. For the energy generation sector, satisfying the demand is a big challenge due to the limitation of conventional energy sources. Hence, new technologies have been developed to generate energy from renewable energy sources. However, estimating the power output of inherently intermittent, weather-driven, and non-scheduled renewable energy resources has become a major scientific and societal concern. In this thesis, we provide a neural network model to enable short-to-middle term forecasts of Photovoltaic (PV) Systems. By using historical weather data from metrology station, a non-linear autoregressive network with exogenous input (NARX) is built to predict the non-linear PV system output power. The performance of the network is then analyzed by using different statistical evaluation parameters. We show that PV System power output estimation method can be successfully employed within Kayseri province in Turkey and can be implemented in other regions as well. This work results in the benefit of solar energy companies in Turkey and can be used for academic purposes.

Keywords: Solar Energy, Photovoltaic (PV), Energy Generation Forecasting, Artificial Neural Network, NARX Model

İÇİNDEKİLER

KAYSERİ İLİ İÇİN GÜNEŞ SANTRALİ ELEKTRİK ENERJİSİ ÜRETİM TAHMİN PLANLAMASI

BİLİMSEL ETİĞE UYGUNLUK.....	i
TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
KISALTMALAR.....	x
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiii
GİRİŞ.....	1

1. BÖLÜM

LİTERATÜR TARAMASI

2. BÖLÜM

GÜNEŞ ENERJİSİ SİSTEMLERİ

2.1. Giriş.....	11
2.2. Güneş Açıları.....	12
2.2.1. Deklinasyon Açısı (δ)	13
2.2.2. Saat Açısı (ω)	14
2.2.3. Enlem (ϕ)	14
2.2.4. Yükseklik Açısı (α)	14
2.2.5. Zenit Açısı (θ_z).....	15
2.2.6. Azimut Açısı (γ_{sun})	15

2.2.7. Geliş Açısı (θ_i).....	15
2.3. Yeryüzündeki Güneş Enerjisi	15
2.3.1. Güneş Sabiti.....	15
2.3.2. Atmosfer Dışı Güneş Işınımı	15
2.3.3. Dünya Yüzeyinde Güneş Radyasyonu	16
2.3.4. Yatay ve Eğimli Yüzeylerde Güneş Radyasyonu	17
2.4. Güneş Enerjisi Potansiyeli.....	18
2.4.1. Küresel Güneş Enerjisi Potansiyeli	18
2.4.2. Türkiye’de Güneş Enerjisi Potansiyeli	19
2.4.3. Kayseri İlinde Güneş Enerjisi Potansiyeli	19
2.5. Güneş Enerji Teknolojileri.....	20
2.5.1. Fotovoltaik Teknolojileri.....	20
2.5.1.1. Monokristal Silikon Teknolojisi	21
2.5.1.2. Polikristal Silikon Teknolojisi.....	21
2.5.1.3. İnce Film Teknolojisi	21

3. BÖLÜM

GÜNEŞ ENERJİSİ ÜRETİM TAHMİNİ

3.1. Tahmin Metodları.....	23
3.1.1. Fiziksel Metodlar.....	23
3.1.1.1. Sayısal Hava Tahmini (NWP).....	24
3.1.1.2. Uydu ve Bulut Görüntü Modelleri	24
3.1.2. İstatistiksel Metod	24
3.1.2.1. Otoregresif Hareketli Ortalama (ARMA) Modeli	25
3.1.2.2. Otoregresif Entegre Hareketli Ortalama (ARIMA) Modeli	25
3.1.2.3. Yapay Sinir Ağları	26
3.1.2.3.1. Yapay Sinir Ağlarının Mimari Yapısı.....	27
3.1.2.3.2. Yapay Sinir Ağlarında Öğrenme.....	29
3.1.2.4. Doğrusal Olmayan Özbağlanımlı Dış Kaynaklı Girdi Modeli (Non-Linear Autoregressive with Exogenous Input, NARX).....	30
3.1.2.4.1. NARX Ağı Mimarisi	30

3.1.2.5. Eğitim Algoritmaları.....	31
3.1.2.5.1. Dik İniş Algoritması.....	31
3.1.2.5.2. Newton Yöntemi.....	32
3.1.2.5.3. Gauss-Newton Algoritması.....	34
3.1.2.5.4. Levenberg-Marquardt Algoritması.....	35
3.1.2.6. Transfer Fonksiyonu.....	36
3.2. Performans Değerlendirmesi	37

4. BÖLÜM

MODEL TASARIMI VE YÖNTEMİ

4.1. Veri Toplanması.....	39
4.2. Veri Ön İşleme.....	40
4.2.1. Veri Düzenleme	40
4.2.2. Veri Temizleme.....	41
4.2.3. Veri Normalizasyonu	43
4.3. Girdi Verileri Seçimi.....	46
4.4. Oluşturulan Narx Ağ Modeli	48

5. BÖLÜM

SONUÇLAR VE TARTIŞMALAR

5.1. Eğitim Sonuçları.....	51
5.2. Tahmin Sonuçları.....	57
5.3. Tartışmalar Ve Gözlemler.....	58
KAYNAKÇA	64
EKLER.....	69
EK 1. MATLAB CODE FOR NARX MODEL.....	69
ÖZGEÇMİŞ.....	73

KISALTMALAR

AC	: Alternatif Akım
AI	: Yapay Zeka
ANFIS	: Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
AR	: Otoregresif
ARIMA	: Otoregresif Entegre Hareketli Ortalama
ARMA	: Otoregresif Hareketli Ortalama
ARIMAX	: Otoregresif Entegre Hareketli Ortalama Dış Girdi
CdTe	: Kadmiyum Tellür
CIGS	: Bakır-İndiyum-Galyum-Selenid
CIS	: Bakır-İndiyum-Selenid
EBP	: Hata Geri Yayılım
FFBP	: Besleme İleri Geri Yayılım
FL	: Bulanık Mantık
GES	: Güneş Enerji Sistemleri
GSR	: Küresel Güneş Radyasyonu
GUI	: Grafik Kullanıcı Arayüzü
HA	: Saat Açısı
LM	: Levenberg-Marquard algoritması
LST	: Yerel Güneş Saati
MA	: Hareketli Ortalama
MAE	: Ortalama Mutlak Hatası
MAPE	: Ortalama Mutlak Yüzde Hatası
MBE	: Ortalama Sapma Hatası
MLP	: Çok Katmanlı Perceptron
MNT	: Minimum Sıcaklık
MRE	: Ortalama Bağıl Hatası
MSE	: Ortalama Karesel Hatası
MXT	: Maksimum Sıcaklık
NARX	: Doğrusal Olmayan Özbağlanımlı Dış Girdili Ağ Modeli
NASA	: Ulusal Havacılık ve Uzay Dairesi

NCMS	: Meteoroloji ve Sismoloji Ulusal Merkezi
NIWA	: Ulusal Su ve Atmosfer Enstitüsü
NMAE	: Normalize MAE
nRMSE	: Normalleştirilmiş Kök Ortalama Kare Hatası
NWP	: Sayısal Hava Tahmini
PRC	: Yağış Miktarı
PRS	: Hava Basıncı
PV	: Fotovoltaik
RBF	: Radyal Temel Fonksiyonları
RMSE	: Kök Ortalama Karesel Hatası
RLH	: Bağıl Nem
SA	: Sinir Ağları
SARIMA	: Mevsimsel ARIMA
SSI	: Güneş Işınım Şiddeti
SVM	: Destek Vektör Makineleri
TMP	: Ortalama Sıcaklık
TSI	: Total SkyImager
WMAE	: Ağırlıklı MAE
WDS	: Rüzgar Hızı
WT	: Dalgacık Dönüşümü
UV	: Ultraviyole ışınları
YSA	: Yapay Sinir Ağı
ZA	: Zenit Açısı

TABLOLAR LİSTESİ

Tablo 1:	Literatür taraması özeti	8
Tablo 2:	Farklı Algoritmaların Özellikleri	36
Tablo 3:	MATLAB Yerleşik Transfer Fonksiyonları [9].....	37
Tablo 4:	Toplanan Veri Parametrelerinin Listesi	40
Tablo 5:	Ön İşlem Sonrası Veri Örneği	44
Tablo 6:	Güneş Enerji Santralinden Üretilen Güç İle Meteorolojik Değişkenler İçin Regresyon Değerleri.....	46
Tablo 7:	Girdi Değişkenlerinin Farklı Kombinasyonlarına Dayalı Girdi Veri Seti	47
Tablo 8:	Tasarlanan NARX Model Parametreleri.....	50
Tablo 9:	Eğitim Performansı Örneği	53
Tablo 10:	Eğitim Performansı Özeti	56
Tablo 11:	Veri Seti 3 için 01/08/2017 ile 08/08/2017 Tarihleri Arasında Güneş Enerjisi Santralinin Tahmini Gücü	57
Tablo 12:	Saatlik Gerçek Güçü Ve Tahmin Güçü	60
Tablo 13:	Tüm Veri Setler İçin Saatlik Tahmin Hatası	63
Tablo 14:	Veri Seti 3 İçin Günlük Gerçek Güç Ve Öngörülen Güç	63
Tablo 15:	Tüm Veri Setler İçin Günlük Tahmin Hatası.....	63

ŞEKİLLER LİSTESİ

Şekil 2.1:	Güneş radyasyon spektrumu	11
Şekil 2.2:	Elektromanyetik Spektrum	12
Şekil 2.3:	P yerinin deklinasyon açısı (δ), enlem (φ) ve saat açısı (ω)	13
Şekil 2.4:	Deklinasyon Açısının Değişimi	14
Şekil 2.5:	Atmosfer Dışı Işınımın Değişimi.....	16
Şekil 2.6:	Küresel Yatay Radyasyonu [19]	18
Şekil 2.7:	Türkiye’de Güneş Enerjisi Potansiyeli	19
Şekil 2.8:	Türkiye’de ve Kayseri’de Küresel Güneş Radyasyonu ve Güneşlenme Süreleri (Saat)	20
Şekil 2.9:	Polikristalin, Monokristalin Ve İnce Film Güneş Panelleri.....	22
Şekil 3.1:	m Girişli YSA	27
Şekil 3.2:	Tek Katmanlı İleri Besleme Ağı	27
Şekil 3.3:	Çok Katmanlı İleri Beslemeli Ağı	28
Şekil 3.4:	Geri Beslemeli Ağı	29
Şekil 3.5:	NARX Mimarisi	31
Şekil 4.1:	Güneş Enerji Santrali Lokasyonu	39
Şekil 4.2:	Toplanan Veriler ve Eksik Verilerin Doldurulması.....	43
Şekil 4.3:	Veri Toplama ve İşleme Akış Şeması.....	48
Şekil 5.1:	Veri Seti 3 İçin Açık Döngü NARX Ağı	51
Şekil 5.2:	Veri Seti 3 İçin Kapalı Döngü NARX Ağı	52
Şekil 5.3:	Veri Seti 3 İçin Kapalı Döngü Modunda NARX Ağ Eğitimi.....	52
Şekil 5.4:	Doğrulama Performansı	55
Şekil 5.5:	Regresyon Performansı.....	55
Şekil 5.6:	Eğitim Durumu	56
Şekil 5.7:	Saatlik Tahmini Ve Beklenen Çıkış Gücü	58

GİRİŞ

Nüfus arttıkça enerji talebi her geçen gün artmaktadır. Birincil enerji kaynakları petrol, gaz, kömür, nükleer, hidro ve yenilenebilir kaynaklardır (güneş, rüzgar, biyokütle, ...). Enerji kaynağı payında petrol, kömür ve gaz, diğerlerine göre daha yüksek orana sahiptir. Ancak yenilenebilir enerji kaynaklarının payı giderek artmaktadır.

Elektrik, kullanıcıya kayıpları en aza indirgeyerek kolay ulaştırılabilen bir enerji türüdür. Bu nedenle, enerji kaynaklarının çoğu elektrik enerjisine dönüştürülmektedir. Enerjinin elektrik enerjisine dönüşümü, çevreye zararlı olan sera gazlarının üretimi gibi dezavantajlarla da ilişkilidir. Elektrik çoğunlukla fosil yakıt kaynaklarından üretilmektedir ve bunların çevre dostu kaynaklar olan yenilenebilir enerji kaynakları için elektrik üretimi ile karşılaştırıldığında sera gazı üretimi yüksektir. Bu nedenle, yenilenebilir enerji kaynaklarının elektrik üretiminde payını artırmak ve sera gazlarını atmosfere salınımını azaltmak için yeni teknolojiler ve politikalar uygulanmaktadır. Bu teknolojiler, güneş enerjisi ve rüzgar enerjisi gibi yenilenebilir enerjilerden mümkün olduğunca verimli bir şekilde elektrik üretimine dayanmaktadır. Bu teknolojiler için en büyük zorluk, yenilenebilir enerji kaynaklarının aralıklı ve değişken olmasıdır.

Güneş enerjisi, yüksek potansiyeli olan fakat hava koşullarına, yılın mevsimlerine, günün vaktine vb. bağlı olarak değişen yenilenebilir enerjilerden biridir. Güneş enerjisinin aralıklı olması nedeniyle tüketicilerin talebini karşılamak için şebekeye entegrasyonu zordur. Bu zorluğun üstesinden gelmek için gelecekte üretilecek enerjinin tahmini bir araç olarak kullanılır. Güneş enerjisi kaynağından üretilecek elektrik, işletme planlaması ve santral optimizasyonu için tahmin edilmelidir.

Bu tez, güneş enerjisi santralinden enerji üretiminin tahmini için bir model tasarlamak amacıyla yapılmıştır. Uygulamanın yapıldığı santral, Kayseri ilindedir.

1. BÖLÜM

LİTERATÜR TARAMASI

PV santralının şebeke entegrasyonu son yıllarda iklim değişikliği ve küresel ısınma nedeniyle önemli bir araştırma konusu haline geldi. PV enerji üretiminin doğru tahmin edilmesi, artan enerji ihtiyacının karşılanması, iklim değişikliğinin hafifletilmesi ve elektrik şebekesi sistemlerinin stabilize edilmesi ihtiyacından dolayı çok önemlidir. PV enerji üretiminin doğru tahmin edilmesi, belirsiz ve rasyonel olmayan meteorolojik faktörlere bağımlılık olmasından dolayı zordur. Endirekt tahmin modeli için, farklı zaman ölçeklerinde, sayısal hava tahmini (NWP), görüntü tabanlı, istatistiksel ve hibrit yapay sinir ağı (YSA) yöntemleri de dahil olmak üzere çeşitli yöntemler kullanılarak, güneş radyasyonu tahmin edilmektedir. Direkt tahmin modeli için, PV enerji üretimi doğrudan tarihsel veri örnekleri kullanılarak tahmin edilir. Direkt tahmin yöntemleri, PV enerji üretiminin doğru tahminini gerçekleştirebilir. Güneş ışınımı, atmosfer sıcaklığı, modül sıcaklığı, rüzgar hızı ve yönü ve bağıl nem gibi hava parametreleri, PV enerji çıkışını tahmin etmek için potansiyel parametreler olarak kabul edilir. Son çalışmalarda, YSA tabanlı tahmin modellerinin hızlı ve değişken çevresel koşullar altında iyi performans verdiği gösterilmiştir [1]. Das ve ark. [1], PV enerji üretimi tahmin edilmesi ve model optimizasyonu üzerine bir inceleme yapmışlardır. İncelenen çalışmalarda, PV enerji üretimi tahmin modellerinin hatasızlığını değerlendirmede ortalama karesel hatası (MSE), kök ortalama karesel hatası (RMSE), normalleştirilmiş kök ortalama kare hatası (nRMSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hatası (MAPE), ortalama bağıl hatası (MRE), normalize MAE (NMAE), ve ortalama sapma hatası (MBE) yaygın olarak kullanılmıştır. Bulgular, RMSE'nin diğerlerinden daha sık kullanıldığını göstermektedir. Das ve arkadaşlarının incelemesine göre, YSA tabanlı modelleme, geleneksel matematiksel modellerden doğruluk ve uyumluluk açısından daha iyi performans göstermektedir. Das ve arkadaşlarının

çalışmasında incelenen YSA modellerinin performansı, nRMSE için %12.5 ile %36.9 arasında ve MAPE için %7.65 ile %18.89 arasındadır.

Cadenas ve ark. [2], tek değişkenli ARIMA modeli ve çok değişkenli Doğrusal Olmayan Özbağlanımlı Dış Girdili Ağ Modeli (Non-linear AutoRegressive network with eXogenous input, NARX) kullanarak rüzgar hızı tahmininde çeşitli meteorolojik değişkenlerin etkileri karşılaştırmalı araştırma yapmışlardır. Analizlerinde, NARX modeli için kullanılan değişkenler barometrik basınç, hava sıcaklığı, rüzgar yönü ve güneş radyasyonu veya bağıl nemdir. Saatlik ortalama ölçümlerin veritabanı için La Mata, Oaxaca, Meksika'dan elde edilmiştir ve on dakika ortalama ölçümlerin veritabanı için Metepec, Hidalgo, Meksika'dan elde edilmiştir. Elde edilen sonuçlar, ARIMA modeli ile rüzgar hızı tahmininde uygun olduğunu ancak NARX modeli kullanılarak daha doğru sonuçları elde edilebildiğini göstermiştir.

Al Shamisive ark. [9], Birleşik Arap Emirlikleri, Al Ain City'de küresel güneş radyasyonunu tahmin etmek için yapay sinir ağı modelleri geliştirmek için MATLAB kullanımı üzerinde çalışmışlardır. Güneş enerji sistemlerinin optimum tasarımı ve çalışması için yatay yüzeydeki güneş radyasyonuna ait bilgilerin önemini açıklayarak çalışmalarına başlamışlardır. Kullanılan veriler, Abu Dabi'nin Meteoroloji ve Sismoloji Ulusal Merkezi'nden (NCMS) 1995 ve 2007 yılları arasında elde edilmiştir. Al Ain City için maksimum sıcaklık, ortalama rüzgar hızı, güneşleme saatleri, ortalama bağıl nem ve güneş radyasyonu kullanılmış. Veriler kullanılmadan önce, eksik veriler problemi çözülmüş, veriler normalleştirme ve rastgele oluşturma metodları kullanılarak önceden işlenmiştir. Çalışmada çok katmanlı perceptron (MLP) ve radyal temel fonksiyonları (RBF) kullanılmıştır. Tasarlanan ağların performansları 11 kombinasyon halinde toplanan veri değişkenleri kullanarak test edilmiştir. Sonuç olarak, geçmiş zaman serileri meteorolojik verilere dayanan MATLAB aracını kullanarak küresel güneş radyasyonunun tahmin edilebileceğini ve bir veya daha fazla girdi parametresinin mevcut olmamasına rağmen YSA modellerinin genel olarak iyi performans gösterdiği görülmüştür. Analiz sonuçlarında, çoğunlukla %90'a yakın deterministik katsayıları ve MBE, MAPE ve RMSE değerleri ile MLP tekniğine göre RBF tekniğinin üstünlüğü gösterilmiştir.

Sandhya ve Kavitha [10] güneş radyasyonunu tahmin etmek için sinir ağı tabanlı yaklaşım önermiştir. Tasarlanan NARX ağ model sistemi, MATLAB yazılımını kullanarak gerçekleştirilmiştir. Önerilen sistemde kullanılan veriler NASA yüzey meteorolojisi ile toplanan meteorolojik veritabanından elde edilmiştir. Her günlük kayıt, şu meteorolojik parametreleri içerir: minimum hava sıcaklığı, maksimum hava sıcaklığı, hava basıncı ve bağıl nem. Yaratılan ve eğitilen NARX modelinde, dört girişli giriş katmanı, gizli katman ve tahmini güneş radyasyonunu veren düğüm çıktılı çıktı katmanı bulunur. Eğitim, doğrulama ve test sonrası, Levenberg-Marquard (LM) algoritması ile eğitilen NARX ağının diğer algoritmalara göre daha hızlı yakınsadığı, eğitim süresinin 1.8 hata oranı olduğu ve regresyon analizinin 0.78 olduğu bulunmuştur. Sonuç olarak, NARX'ın, giriş ve çıkış değişkenleri arasındaki ilişkiyi tanıması ve güneş radyasyonunu doğru bir şekilde tahmin edebilme yeteneğine sahip olduğu ve NARX modelinin ileri beslemeli sinir ağı tekniklerinden daha doğru sonuçlar verdiği sonucuna varmışlardır.

Ahmad ve Anderson [4] Yeni Zelanda için yapay sinir ağı modelleri kullanarak güneş radyasyonu tahmini önermiştir. Kullanılan veriler, Ulusal Su ve Atmosfer Enstitüsü (NIWA) veritabanından toplanan sıcaklık, hava basıncı, bağıl nem, güneş zenit açısı, azimut açısı, yağış miktarı, rüzgar hızı ve rüzgar yönü için yedi yıl (2006-2012) saatlik verilerdir. Küresel güneş radyasyonu hedef değişkenidir. Her bir hava durumu parametresinin küresel güneş radyasyonu üzerindeki etkisini göz önüne alındığında, önerilen YSA'nın tahmin doğruluğunun çeşitli hava durumu değişkenleri kombinasyonlarına bağlı olduğu bulunmuştur. Bununla birlikte, 9 hava durumu tahmincisinin 12 önemli kombinasyonu test edilmiştir. Toplanan verileri ve seçilen değişkenlerin kombinasyonlarını kullanarak, küresel güneş radyasyonu tahmini için NARX sinir ağ modeli geliştirilmiştir. Birkaç denemeden sonra, çalışma sonuçları, 90 gizli nöron ağı ve 2 gecikme ağı, doğruluğunu ve işlem süresini göz önünde bulundurarak en uygunu olduğunu göstermiştir. Gerçek veriler ile sinir ağı çıktı değişkeninin tatmin edici bir tahmin sağlayabileceğini gösterilmiştir ve YSA'nın daha sonraki zamanlarda radyasyon değerlerini tahmin etme kapasitesini gösterdiği sonucuna varılmıştır.

Ahmad, Anderson ve Lie [5], Yeni Zelanda saatlik güneş radyasyonu tahmini için gelecekteki güneş kontrol sistemine uygulanabilecek birkaç tekniği araştırmışlar ve

NARX modelinin yeteneğini vurgulamışlardır. NARX, MPL, ARMA ve persistans gibi çeşitli teknikler denenmiştir. Kullanılan veriler (sıcaklık, barometrik basınç, bağıl nem, güneş zenit açısı, azimut açısı, toplam yağış, rüzgar hızı ve rüzgar yönü) Ulusal Su ve Atmosfer Enstitüsü (NIWA) veritabanından (2014) elde edilmiştir. 24 saat sonrası küresel güneş radyasyonu hedef çıktı değişkenidir. Test edilen tekniklerin sonuçlarına göre, ARMA yaklaşımı yıllık RMSE değerleri bakımından iyi performans göstermiştir. Aynı şekilde, MPL yaklaşımı bazı günlerde iyi performans göstermiş, ancak veri seti sayısı arttıkça RMSE değeri artmaktadır. Özellikle NARX yaklaşımı, kısa vadeli ve uzun vadeli tahminlerde iyi performans gösterir ve test edilen diğer tahmin yaklaşımları arasında en düşük yıllık RMSE'ye sahiptir. NARX'i en iyi yaklaşım olarak seçtikten sonra Yeni Zelanda'daki on şehirdeki küresel güneş radyasyonunu tahmin etmek için kullanmışlardır. NARX yaklaşımından elde edilen sonuçlar, genelleme kapasitesini ve çeşitli lokasyonlara çevrilebilen küresel radyasyon için doğru tahminler üretme becerisini göstermiştir. Böyle bir NARX tahmin modelinin, güneş enerjisi üretim sistemlerinin daha iyi yönetimi için gelecek güneş kontrol cihazlarında kullanılabileceği belirtilmiştir.

Mohammed ve ark. [6], Ürdün, Amman'da saatlik güneş radyasyonu tahmini için NARX sinir ağına dayalı saatlik güneş radyasyonu tahmini üzerinde çalışmışlar. Çalışmada MATLAB kullanılarak model oluşturulmuş ve test edilmiş ve farklı eğitim algoritmaları kullanılarak eğitilmiştir. Modelin eğitimi 2004-2007 yılları arasındaki meteorolojik veriler kullanılarak gerçekleştirilmiş ve 2008 yılı verileri test için kullanılmıştır. Sonuçlar, Levenberg-Marquardt algoritması ile eğitilen NARX ağının daha hızlı yakınsadığını göstermiştir. Elde edilen sonuçlara dayanarak, Ürdün ve yakın bölgelerdeki saatlik güneş radyasyonunu tahmini için NARX modeli önerilmiştir.

DiPiazza ve ark. [8], NARX sinir ağlarını kullanarak güneş ve rüzgar tahmini üzerine araştırma yapmışlar. Kullanılan veriler, saatlik maksimum ve minimum sıcaklık, saatlik küresel güneş radyasyonu ve saatlik rüzgar hızıdır. Veriler, Palermo, İtalya'da ölçüm istasyonundan elde edilmiştir ve 2002'den 2008'e kadarki yedi yıla aittir. 8 ile 24 saat arası için saatlik güneş ışınlaması ve rüzgar hızı, NARX ağ modeli tarafından tahmin edilmiştir. NARX performansı, nRMSE ve RMSE sonuçlarına göre güneş ışınlama tahmini için sırasıyla %6.1 ve %32 ve rüzgar hızı tahmini için %7 ve %47'dir. Önerilen

NARX ağı modelinin PV ve rüzgar enerjisi üretiminin tahminini geliştirmesine izin verdiği ve akıllı şebeke yönetim sistemi içinde uygulanabileceği gösterilmiştir.

Kardakos ve ark. [12], PV güç üretiminin kısa vadeli tahmininde zaman serileri ve YSA modelleri uygulamalarını incelemiştir. Çalışmada, Yunan enerji sistemlerinin farklı PV santrallerinde tahmin modellerinin uygulamasından elde edilen simülasyon sonuçlarını sunmuşlardır. Kullanılan tahmin modelleri, mevsimsel otoregresif bütünleştirilmiş hareketli ortalama (ARIMA) zaman serisidir ve NWP modelleri ve çoklu girdileri olan yapay sinir ağlarından türetilen kısa vadeli güneş radyasyonu tahminleri birleştirilerek daha da geliştirilmiştir. Kullanılan veriler, dört PV santralının saatlik gerçek PV üretimi ve PV santrali alanlarına bitişik olarak bulunan dört hava istasyonundan toplanan saatlik radyasyon ölçümleridir. Toplanan veriler, 2011 ile 2012 yılları arasındadır. Sonuçlar, mevsimsel ARIMA (SARIMA) modelinin, yıllık ortalama nRMSE açısından en iyi performansı sergilediğini göstermiştir. Dahası, PV enerji tahmini için mevcut dış güneş radyasyonundan faydalanan modeller, yani modifiye SARIMA modeli ve YSA modelleri, gün öncesi tahminlerinde, nRMSE'nin daha düşük olmasına yol açtığı için tercih edilir.

Tao ve ark. [3], güneş radyasyon ölçümünü kullanmadan şebekeye bağlı fotovoltaik güç sistemi için güç çıkışı tahminini incelemiştir. Modelde, adaptif NARX ağına dayalı yeni bir PV güç tahmin yöntemi önerilmiştir. Kullanılan veriler, tahmin edilen ağa girdi olarak hesaplanan ve açık gökyüzü koşullarında güneş radyasyonunun saatlik değerleridir. Ayrıca, bulutlu ve yağışlı günlerde radyasyon değişimini karakterize etmek için, açık web sitesinden hava durumu tahmini, tahmin modelinin kalan girdisi olarak kabul edilmiştir. Ertesi günün saatlik PV gücü ağın çıkış vektörü olarak alınmıştır. Tasarlanan NARX ağı, ağ ağırlıklarını elde etmek için geçmiş girdi ve çıktı değerleriyle eğitilmiştir. Deneysel sonuçları, önerilen metodun, hava aniden değişse bile PV gücü çıktısını tahmin edebildiğini ve bir gün içinde saatlik gücün değişimini gösterebildiğini ortaya koymuştur. PV enerjisi üretiminde radyasyonun, sıcaklığın ve hava durumunun efektif analizine dayanılarak NARX ağı PV sistemlerinin çıktısını tahmin etme yeteneğine sahip olduğu sonucuna varmışlardır.

Sharma, Pander ve Chaudhary [7] sinir ağı zaman serisi metodunu kullanarak güneş enerjisi üretimini tahmin sistemi önermişlerdir. YSA modeli, NARX modeline

dayanarak geliştirilmiştir. Kullanılan veriler, 2014 yılının 12 ayı için günlük 24 saat ortam sıcaklığı ve 365 gün boyunca günlük hücre sıcaklığından oluşmaktadır. Çıktı verileri, Jaipur şehrindeki RCWA Koleji için günlük AC güneş enerjisi tahminidir. Ağ, Levenberg-Marquardt algoritması tarafından eğitilmiş ve gecikme sayısı ve gizli nöron sayısı sırasıyla 2 ve 20'dir. Sonuçlar, modelin son derece büyük bir verimlilik seviyesinde sonuç verdiğini ve performansa göre en iyi RMSE katsayısının 7.5 olduğunu göstermiştir.

Tablo 1'de, literatür taramasında incelenen çalışmaların bir özeti verilmektedir. Literatür taraması sonucunda, bu tezde tahmin modeli olarak NARX modeli kullanılmasına ve modelin Levenberg-Marquardt algoritması, dividrand bölme fonksiyonu ve hiperbolik teğeti sigmoid transfer fonksiyonu tarafından eğitilmesine karar verilmiştir.

Tablo 1: Literatür taraması özeti

(*GD: Giriş düğümü, GKD: Gizli katman düğümleri, ÇD: Çıkış düğümü)

Araştırmacılar	Hedef	Veri tipi	Tahmin modeli	YSA için model mimarisi			Transfer fonksiyonu	Tahmin hatası	Tahmin ufku
				GD	GKD	ÇD			
Cadenas ve ark. (2016)	Rüzgar hızı	Rüzgar hızı ve yönü, Hava sıcaklığı, Barometrik basıncı ve Küresel Güneş radyasyonu, ve Bağlı nem	ARMA NARX	4	10	1	Sigmoid	Saatlik veritabanı için MAE %5.5 ve dakika veritabanı için %2.3 Saatlik veritabanı için MSE %10.6 ve on dakikalık veritabanı için %12.8	10 dakika önde 1 saat önde
Al Shamisi ve ark. (2011)	Güneş radyasyonu	Maksimum sıcaklığı, Ortalama rüzgar hızı, Güneş yoğunluğu, Ortalama bağlı nem ve Güneş radyasyonu	YSA (RBF ve MLP)	2-4	30-195	1	Teğet sigmoid, log sigmoid, ve doğrusal	Determinasyon katsayısı 0.80-0.93, RMSE 0.349-0.616	1ay önde
Sandhya ve Kavitha (2015)	Güneş radyasyonu	Minimum hava sıcaklığı, Maksimum hava sıcaklığı, Hava basıncı, Bağlı nem, ve Güneş radyasyonu	NARX	4	10	1	-	MSE 1.5-6 ve Regresyon Analizi 0.16-0.78	-

Ahmad ve Anderson (2014)	Küresel Güneş radyasyonu	Sıcaklık, Hava basıncı, Bağıl nem, Güneş zenit açısı, Azimut açısı, Yağış miktarı, Rüzgar hızı ve yönü, ve Küresel Güneş radyasyonu	NARX	3-9	10-250	1	-	Regresyon (R) 0.949-0.963, MSE 0.0591-0.0722	24 saat önde
Ahmad, Anderson ve Lie (2014)	Küresel güneş radyasyonu	Sıcaklık, Barometrik basınç, Bağıl nem, Güneş zenit açısı, Azimut açısı, Yağış, Rüzgar hızı ve yönü, ve Küresel güneş ışımasını	NARX	3-9	5-250	1	-	RMSE 0.243-0.280 MJ/m ² . Regresyon (R) 0.949-0.963	24 saat önde
Mohammed ve ark. (2013)	Küresel güneş radyasyonu	Meteorolojik verileri (detay verilmemiş)	NARX	-	-	-	-	Determinasyon katsayısı (R) 0.98692- 0.99157 , RMSE 42.8367-53.2732MJ/m ² /saat, MBE 25.5612-32.5375 MJ/m ² /saat	24 saat önde
DiPiazza ve ark. (2016)	Küresel güneş radyasyonu ve Rüzgar hızı	Maksimum ve minimum sıcaklığı, saatlik küresel güneş radyasyonu ve saatlik rüzgar hızı	NARX YSA	1	-	2	-	Normalize RMSE 0.260-0.588, Varyasyon katsayısı of RMSE 0.635- 3.098	8-24 saat önde

Kardakos ve ark. (2013)	PV gücü	Saatlik gerçek PV üretimi ve saatlik Güneş radyasyonu	YSA Mevsimsel ARIMA	7	4	1	-	Normalize RMSE 3,17- 20,35	1gün önde
Tao ve ark. (2010)	PV gücü	Ertesi gün açık gökyüzü radyasyonu ve ertesi gün için hava tahmini ve PV güç üretimi	NARX YSA MLP YSA	2	-	1	Teğet sigmoid ve Log-sigmoid	MAPE %16.47-%30.72	-
Sharma, Pander ve Chaudhary (2016)	Güneş enerjisi	Saat ortam sıcaklığı, Günlük hücre sıcaklığı, AC güneş enerjisi	NARX YSA	2	-	1	log-sigmoid ve doğrusal	MSE 7.5	24 saat önde
Das ve ark. (2018)	PV gücü	Meteorolojik veriler (farklı çalışmalar incelenmiş)	Devamlılık ARIMA YSA SVM Hibrid	-	-	-	-	Normalize MAE (NMAE) <1 to 19.49%, ve ağırlıklı MAE (WMAE) < 2, nRMSE %2.74-%36.9, MAPE %2.38-%18.89, MRE %8.64-%17.58, MSE 21.8, MBE<%1.3, RMSE %2.7-%19.663, MAE %3.38-%21.02	1 dakikadan 24 saate kadar önde

2. BÖLÜM


GÜNEŞ ENERJİSİ SİSTEMLERİ

2.1. Giriş

Güneş enerjisi, güneş radyasyonundan elde edilen enerji olarak tanımlanır. Güneş enerjisi, yılın 365 günü günün 24 saati aşırı yüksek ve nispeten sabit bir oranda elektromanyetik radyasyon olarak yayılır. Daha uzun dalga boyları daha kısa olanlardan daha az enerjiye sahiptir. Güneş radyasyonunun toplam spektrumuna geniş anlamda güneş ışığı denir. Şekil 2.1 ve 2.2 sırasıyla güneş radyasyon spektrumunu ve elektromanyetik spektrumunu göstermektedir. Güneş radyasyon spektrumu, Plank yasası kullanılarak hesaplanır. Şekil 2.1'de görüldüğü gibi, radyasyon spektrumunun maksimum noktası görünür spektrumda bulunur, ancak önemli miktarı kısa ve uzun dalga boyunda da var olur.



Şekil 2. 1: Güneş radyasyon spektrumu

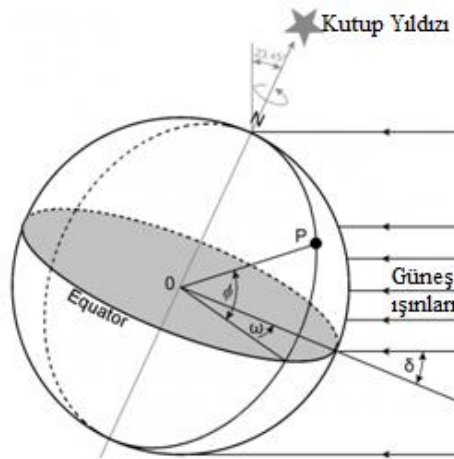


Şekil 2. 2: Elektromanyetik Spektrum

Güneş radyasyonları, Dünya'nın atmosferinden geçerken atmosferik absorpsiyon ve saçılma mekanizmalarına maruz kalır. Güneşin X-ışınları ve aşırı UV ışınları ionosferde azot, oksijen ve diğer atmosferik gazlar tarafından emilir. Ozon ve su buharı, ultraviyole ve kızılötesi radyasyonların büyük oranını absorbe eder. Atmosferde, kısa dalga radyasyonlarının tam emilmesi sağlanır. Bu nedenle, dünya yüzeyinde, güneş radyasyonu spektrumlarının 0.29 mm 'nin altında ve 2.3 mm 'nin üstünde kalan dalga boyu enerjisi ihmal edilebilir.

2.2. Güneş Açıları

Yerin enlemi, saat açısı ve güneşin eğim açısı biliniyorsa, Dünya yüzeyinin güneş ışınlarına göre durumu herhangi bir yer ve herhangi bir anda bilinir. Bu bölümde, hesaplamalarda kullanılan açılar kısaca anlatılacaktır.



Şekil 2.3: P yerinin deklinasyon açısı (δ), enlem (φ) ve saat açısı (ω)

2.2.1. Deklinasyon Açısı (δ)

Deklinasyon açısı, ekvator ve dünya merkezini birleştiren çizgi ile güneş ışınları arasındaki açıdır (Şekil 2.3). Dünya'nın dönüşü ve devrimi nedeniyle mevsimsel olarak değişir. Dünya'nın dönme eksenini, Dünya'nın yörüngesine dik değildir, Güneş'teki Dünya hareketinin düzlemine göre 23.45° eğiktir. Dönme eksenlerinin eğimi nedeniyle deklinasyon açısının maksimum ve minimum değerleri sırasıyla 23.45° ve -23.45° 'dir. Yılın herhangi bir günündeki deklinasyon açısı aşağıdaki fonksiyonu kullanarak elde edilir.

$$\delta = 23.45^\circ \sin\left[(284 + n) \times \frac{2\pi}{365}\right] (1)$$

Kış gündönümü zamanında güneş ışınları, ekvatorun 23.45° güneyindedir ($\delta = -23.45^\circ$). Yaz gündönümünde güneş ışınları, ekvatorun 23.45° kuzeyindedir ($\delta = 23.45^\circ$). Ekinokslarda güneşin deklinasyon açısı değerini sıfırdır. Yıl boyunca deklinasyon açısının değişimi Şekil 2.4'te verilmiştir.



Şekil 2. 4: Deklinasyon Açısının Değişimi

2.2.2. Saat Açısı (ω)

Saat açısı, meridyen düzlemini herhangi bir yeri güneşin altına getirmek için dünyanın dönmesi gereken açıdır. Saat açısı, ω , yerinden Dünya'nın merkezine projeksiyon ile Güneş'in merkezinden Dünya'nın merkezi çizgisinin projeksiyonu arasındaki yeryüzünün ekvatorial düzleminde ölçülen açıdır. Öğle vaktinde, saat açısı sıfırdır. Saat açısı öğlene göre günün saatini ifade eder. Bir saatlik zaman 15° saat açısını temsil eder. Öğlen öncesinde, saat açısı negatif ve öğlen sonrasında pozitiftir. Herhangi bir yerin saat açısı, Yerel Güneş Saatinin (LST) fonksiyonuyla aşağıdaki denklemle ifade edilir.

$$\omega = 15^\circ \times (LST - 12) \quad (2)$$

2.2.3. Enlem (ϕ)

Enlem, ekvatorun kuzeyi (veya güneyi) ile bir yerin açısal mesafesidir. Verilen yer ile Dünya'nın merkezini birleştiren çizgi ve onun ekvatoryal düzlemdeki projeksiyonu tarafından oluşturulan açıdır. Yer, ekvatorun kuzeyinde ise enlem açısı pozitif, güneyinde ise negatiftir.

2.2.4. Yükseklik Açısı (α)

Yükseklik açısı, gökyüzünde yatay olarak ölçülen güneşin açısal yüksekliğidir. Yükseklik açısı, güneşin doğuşunda 0° ve güneş tepede olduğunda 90° 'dir. Yükseklik açısı gün boyunca değişir ve yerinin enlemine ve yılın gününe bağlıdır. Yükseklik açısı aşağıdaki denklem kullanarak elde edilebilir:

$$\sin\alpha = \sin\delta\sin\phi + \cos\delta\cos\omega\cos\phi \quad (3)$$

2.2.5. Zenit Açısı (θ_z)

Zenit açısı, güneş ile dikey düzlem (zenit yönü) arasındaki açıdır.

$$\theta_z = 90^\circ - \alpha \quad (4)$$

2.2.6. Azimut Açısı (γ_{sun})

Azimut açısı güneyden güneş ışınlarının yatay izdüşümüne kadar ölçülen yatay düzlemdeki açıdır. Azimut açısı, γ_{sun} , güneyin doğusunda negatif, güneyin batısında pozitifdir. Enlem ve yılın zamanına göre değişir ve aşağıdaki denklem ile hesaplanır:

$$\cos(\gamma_{sun}) = \frac{1}{\cos\alpha} (\cos\delta\sin\phi\cos\omega - \sin\delta\cos\omega) \quad (5)$$

2.2.7. Geliş Açısı (θ_i)

Güneşin geliş açısı, insidans noktasındaki yüzeye gelen ışın ile yüzeye dik çizgi arasındaki açıdır. Güneş ışınları ile normal yüzey arasındaki açıdır. Geliş açısı, aşağıdaki denklem ile ifade edilir:

$$\cos\theta_i = (\cos\phi\cos\beta + \sin\phi\sin\beta\cos\gamma)\cos\delta\cos\omega + \cos\delta\sin\omega\sin\beta + (\sin\phi\cos\beta - \cos\phi\sin\beta\cos\gamma)\sin\delta \quad (6)$$

2.3. Yeryüzündeki Güneş Enerjisi

2.3.1. Güneş Sabiti

Güneş yüzeyindeki güneş radyasyonunun yoğunluğu yaklaşık $6.33 \times 10^7 \text{ W/m}^2$ 'dir. Güneş radyasyonu uzaya yayılır ve buna göre radyasyonun şiddeti azalır. Güneş radyasyonu Dünya atmosferinin kenarına ulaştığı zaman güneş ışınları 1367 W/m^2 şiddetiyle paralel olarak kabul edilir [14, 15]. Güneş sabiti, dünyanın atmosfer kenarına ulaşan ortalama güneş ışını olarak tanımlanır ve $I_{sc} = 1367 \text{ W/m}^2$ ile gösterilir.

2.3.2. Atmosfer Dışı Güneş Işınımı

Yüzeye düşen güneş radyasyonunun şiddetine ışınım ve güneşlenme denir ve birimi W/m^2 veya kW/m^2 'dir. Güneş ve dünya arasındaki uzaklığın değişmesi nedeniyle,

dünya eliptik yolda güneşin etrafında dönerken, dünyanın atmosferi dışında alınan güneş radyasyonunun şiddeti değişir [15]. Yılın n 'inci günü radyasyona normal olan düzlemdeki atmosfer dışı ışınımın şiddeti, yaklaşık olarak aşağıdaki gibi verilir:

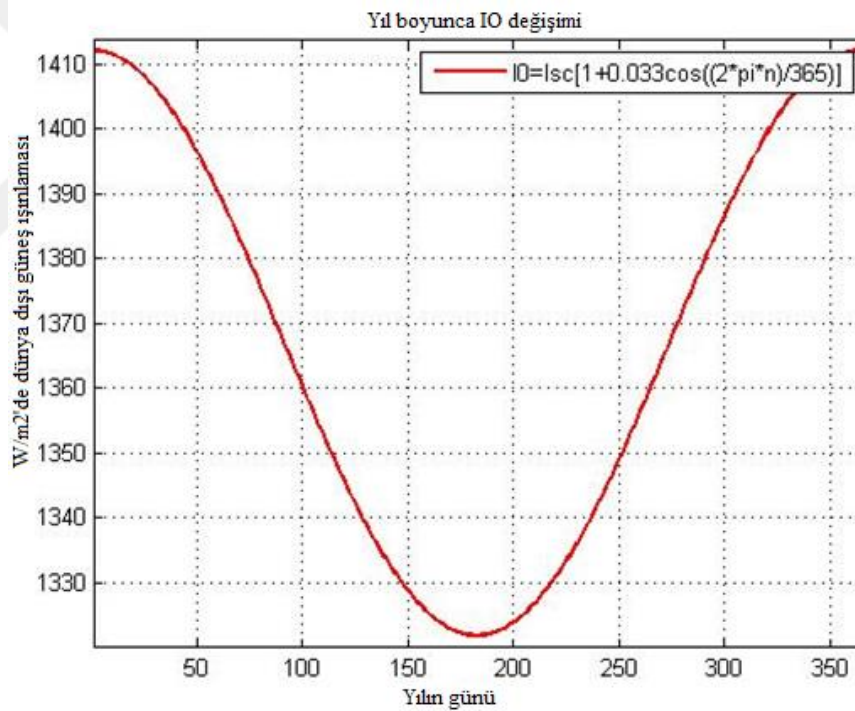
$$I_0 = I_{SC} \left[1 + 0.033 \cos \left(\frac{360 \times n}{365} \right) \right] \quad (6)$$

I_0 = atmosfer dışı ışınım

I_{SC} = güneş sabiti

n = yılın günü, Ocak 1'inci için $n = 1$

Atmosfer dışı ışınımın değişimi, Şekil 2.5'te verilmiştir.



Şekil 2. 5: Atmosfer Dışı Işınımın Değişimi

2.3.3. Dünya Yüzeyinde Güneş Radyasyonu

Dünya atmosferi üzerindeki gelen güneş radyasyonu neredeyse sabittir. Yeryüzü yüzeyindeki radyasyon, absorpsiyon ve saçılma, buhar, bulutlar ve atmosfer kirliliği, yerin enlemi, yılın mevsimi ve günün saati gibi atmosferik etkilere bağlı olarak büyük ölçüde değişir. Bulutlar, dünyanın yüzeyine ulaşan güneş radyasyonu miktarını

belirleyen baskın atmosferik koşullardır. Bulutlu iklimlere sahip bölgeler, bulutlu olmayan iklim bölgelerinden daha az güneş ışınımı alır. Herhangi bir yer için, yeryüzüne ulaşan güneş radyasyonu bulut örtüsünün artmasıyla azalır. Güneş radyasyonunun miktarı da günün saatine ve mevsime bağlıdır. Genel olarak, öğleye doğru ve öğleden sonra saatlerinde fazla güneş radyasyonu bulunur. Öğlen dünyaya gelen güneş ışınlarının yolu kısadır. Sonuç olarak, daha az güneş radyasyonu saçılır ya da emilir ve daha fazla güneş radyasyonu yeryüzüne ulaşır. Kuzey yarımkürenin güneye bakan yüzeyinde gün ortasında daha fazla güneş ışını alınır, çünkü güneş ışınları yaklaşık yüzeye diktir. Kuzey yarımkürede yaz boyunca daha fazla güneşlenme olması nedeniyle kışa göre daha fazla güneş ışını beklenir. Hem insan yapımı hem de doğal olarak oluşan olaylar, dünyanın yüzeyindeki güneş radyasyonu miktarını sınırlayabilir. Kent havası kirliliği, orman yangınlarından çıkan duman ve volkanik aktiviteler güneş radyasyonunun saçılması ve absorpsiyonunu arttırarak güneş ışınlarını azaltır. Doğrudan ışımdan bazıları yeryüzüne dağılır ve yaygın ışınım olarak adlandırılır. Doğrudan ışınım, dünya yüzeyi ve güneşi birleştiren çizgide yayılan güneş radyasyonu olarak tanımlanır. Direkt ışınım ve direkt doğrudan ışınım olarak da adlandırılır. Yaygın ışınım atmosferde bulunan parçacıklar tarafından dağılan güneş radyasyonu olarak tanımlanır. Başka bir radyasyon tipide yansıyan radyasyon olarak adlandırılır ve yüzeylerden (evler, ağaçlar, dağlar, su vb.) yansıyan güneş radyasyonunun parçası olarak tanımlanır. Genellikle küresel radyasyon olarak adlandırılan toplam radyasyon, dünya yüzeyinde bulunan toplam güneş radyasyonunun miktarıdır ve doğrudan, yaygın ve yansıyan ışımdan oluşur.

2.3.4. Yatay ve Eğimli Yüzeylerde Güneş Radyasyonu

Dünya yüzeyinde yatay düzlemde meydana gelen güneş enerjisi formlarının kombinasyonu, küresel güneş enerjisi olarak adlandırılır ve aşağıdaki denklem yardımıyla elde edilebilir.

$$I_G = I_N \cos\theta_z + I_D \quad (7)$$

I_G = Yatay yüzeyinde küresel ışınım

I_D = Yaygın ışınım

I_N = Doğrudan radyasyonunda dikey yüzeyindeki doğrudan ışınım


θ_z = Güneş zenit açısı

Üç bileşeni ayrı ayrı ölçerek, ölçülen miktarı hesaplanan değer ile karşılaştırarak yararlı bir kalite güvence testi hazır olur. Böylece, küresel güneş ışınımı, dünya yüzeyinde yatay bir düzlem üzerinde toplam gelen güneş enerjisinin oranının (doğrudan ve yaygın) bir ölçüsüdür. Bu miktarı sınırlı doğrulukla ölçmek için bir piranometre kullanılır. En doğru ölçümler, doğrudan ışınımın yaygın ve yatay bileşenini toplayınca elde edilir [15].

2.4. Güneş Enerjisi Potansiyeli

2.4.1. Küresel Güneş Enerjisi Potansiyeli

Güneş enerjisinden elde edilen elektrik, küresel ısınmaya katkıda bulunmayan en temiz enerji kaynaklarından biridir. Güneş enerjisi, dünya üzerindeki en büyük enerji kaynağıdır [18]. Güneş ışığından dünyaya saatte gelen enerji, yıl boyunca insanlar tarafından tüketilen enerjiden daha yüksektir. Aslında, güneş enerjisinin kaynağı diğer yenilenebilir ve fosil esaslı enerji kaynaklarından daha fazladır [16]. 174 Petawatt (PW) enerji, güneş radyasyonu şeklinde atmosfere girer. Bunun üçte biri uzaya geri yansıtılır.




Şekil 2. 6: Küresel Yatay Radyasyonu [19]

Şekil 2.6, dünyanın çeşitli bölgelerinde küresel güneş enerjisi potansiyelini göstermektedir. Ekvatora daha yakın bölgeler, kuzey veya güney bölgelerinden daha fazla yıllık güneş enerjisi potansiyeline sahiptir. Örneğin, İskandinavya, Kuzey Kanada ve Rusya'nın tümünde günde 2.0 kWh/m²'nin altındaki potansiyeller bulunurken, Güney Amerika ve Afrika'nın bazı bölgelerinde 7.5 kWh/m²'nin üzerinde potansiyel bulunmaktadır. Bu, günümüzdeki fakir ülkelerden birçoğunun gelecek yıllarda enerji

altın madeni üzerinde oturabileceği anlamına geliyor [19]. Maalesef, tüm güneş enerjisi potansiyelinden yararlanılamaz. Güneş enerjisi aralıklı kaynaktır, her zaman mevcut olmadığı anlamına gelir. Güneş ışığı her zaman dünya yüzeyine gelir; ancak dünyanın kendi etrafında döndüğü gerçeği nedeniyle, güneş enerjisi gece gündüz tek bir yerde sürekli bulunmaz.

2.4.2. Türkiye’de Güneş Enerjisi Potansiyeli

Kuzey yarımküredeki yeri ile (36-42N enlem ve 26-45E boylamları), Türkiye yüksek güneş enerjisi potansiyeline sahiptir. Türkiye’de yıllık toplam güneşlenme süresi 2640 saat (7.2 saat/gün) ve yıllık güneş radyasyonu 1311 kWh/m²-gün’dür. Türkiye’nin güneş enerjisi potansiyeli 380 milyar kWh/yıl olarak hesaplanmaktadır [21]. Haziran, Temmuz ve Ağustos ayları, Türkiye’de güneş enerjisini kullanmak için en verimli aylardır. En az verimli aylar Kasım, Aralık ve Ocak aylarıdır. Güneydoğu Anadolu ve Akdeniz, Türkiye için en yüksek güneş potansiyeline sahip bölgeleridir. İç Anadolu’nun geniş düz arazileri, güneş enerjisi yatırımları için oldukça kârlı alanlardır. Karadeniz Bölgesi hariç Türkiye ortalama 2640 saat güneş ışığından metre kare başına 1100 kWh üretebilir [22]. Şekil 2.7, Türkiye’nin güneş radyasyonu potansiyelini göstermektedir.



Şekil 2. 7: Türkiye’de Güneş Enerjisi Potansiyeli

2.4.3. Kayseri İlinde Güneş Enerjisi Potansiyeli

Kayseri ili, 38°44'5.2872"N ve 35°28'4.7532" E koordinatlarıyla Türkiye’nin ortasında bulunmaktadır. Kayseri’deki güneş radyasyonu 1600-1700 kWh/m²-yıl arasındadır. En uzun güneşlenme süresi Nisan ve Eylül ayları arasındadır ve günlük ortalama güneşlenme süresi 7 ile 12 saat arasındadır [23, 24].



Şekil 2. 8: Türkiye’de ve Kayseri’de Küresel Güneş Radyasyonu ve Güneşlenme Süreleri (Saat)

Şekil 2.8’e göre; Kayseri’de maksimum küresel güneş radyasyonun değeri ve güneşlenme süresi, sırasıyla 6.85 kWh/m²-gün ve 12.03 saat ile Temmuz ayında ortaya çıkmaktadır. Türkiye için genel olarak maksimum güneş ışınımı değeri Haziran ayında 6.57 kWh/m²-gün ve en yüksek güneşlenme süresi Temmuz ayında 11.31 saat değeriyle ortaya çıkmaktadır.

2.5. Güneş Enerji Teknolojileri

2.5.1. Fotovoltaik Teknolojileri

Fotovoltaik teknolojileri, fotovoltaik etki gösteren malzemeleri kullanarak güneş enerjisini doğru akım (DC) elektrik enerjisine dönüştürmek için kullanılır. Günümüzdeki fotovoltaik teknolojileri için kullanılan malzemeler monokristal silikon, polikristalin silikon, amorf silikon, kadmiyum tellür ve bakır indiyum galyum selenit/sülfür’dür. Fotovoltaik (PV) teknoloji, günümüzde güneş enerjisinden elektrik üretmek için dünyada en çok kullanılan güneş enerjisi teknolojisidir. Işıkla beslenen güneş pilleri, herhangi bir hareketli parça olmadan, ortam sıcaklığına yakın çalışır ve herhangi bir ölçekte üretim yapılmasını sağlar. Güneş pilleri güneş modülünü

oluşturmak için seri ve paralel bağlanır. Fotovoltaik enerji üretimi, fotovoltaik malzeme içeren bir dizi güneş pilinden oluşan güneş panel modüllerini kullanır [25]. Fotovoltaik etki, görünür veya morötesi ışığı gibi çok kısa dalga boyundaki elektromanyetik radyasyondan enerji absorbe etmesi sonucunda maddelerin elektron yayması olarak tanımlanır. Fotovoltaik teknolojileri güneş PV panellerinin yapıldığı malzemelere göre sınıflandırılır, bunların arasında mono-kristalin silikon, polikristal silikon ve ince film teknolojileri en çok kullanılan modeldir.

2.5.1.1. Monokristal Silikon Teknolojisi

Monokristal, 1955 yılında icat edilen ilk PV teknolojisidir. Monokristal silikon hücreleri 25 yıla kadar ömürlü olabilir. Her hücre tek bir kristalden kesildiği için koyu mavi tek bir renge sahiptir. Verimliliği %24'e kadardır ve zamanla %0.5 azalmaktadır. Bu güneş pilleri türü, diğer güneş pilleri teknolojilerine göre en verimli olandır ve daha pahalıdır.

2.5.1.2. Polikristal Silikon Teknolojisi

Polikristal hücreleri, çoklu taneleri ve silikon kristallerinin plakalarını ince levhasına birleştirerek yapılırlar. Daha küçük silikon parçalarını üretmek daha kolay ve daha ucuzdur, bu nedenle bu tür PV maliyeti mono-kristal silikon hücrelerinden daha azdır. Polikristal hücreleri daha az verimlidir (yaklaşık %12). Polikristal hücreleri de çok dayanıklıdır ve 25 yıldan daha uzun ömrü olabilir.

2.5.1.3. İnce Film Teknolojisi

İnce film güneş panelleri, monokristal veya polikristal güneş panellerinden çok daha ince bir fotovoltaik seviye kullanır. İnce film güneş pilleri, kristal silikon hücreleri için 200 ila 300 nm tabakalarla karşılaştırıldığında yaklaşık 10 nm kalınlığında aktif materyal tabakalarından oluşur. 20 yılı aşkın araştırma ve geliştirmeden sonra ince film güneş pilleri yayılmaya başlamıştır. Silikon levha ile karşılaştırıldığında, ince film elektrik üretim maliyetini oldukça düşürmüştür. Ticarileştirilmiş dört ana tip ince film güneş pili, amorf silikon (aSi/ μ c-Si), kadmiyum tellür (CdTe), bakır-indiyum-selenid (CIS) ve Bakır-indiyum-galyum-selenid (CIGS)'dir. Günümüzde, CdTe hücreleri ince film pazarında hakim bir konuma gelmiş ve pazarda lider watt başına maliyete sahiptir. Ancak, bu malzemeler toksiktir ve silikondan daha az miktardır [25, 26, 27].



Şekil 2. 9: Polikristalin, Monokristalin ve İnce Film Güneş Panelleri

3. BÖLÜM

GÜNEŞ ENERJİSİ ÜRETİM TAHMİNİ

3.1. Tahmin Metodları

Güneş enerjisiyle elektrik üretimi sürekli olarak artmaktadır. Güneş enerjisi santralının çıktı gücü, küresel güneş radyasyonu, hava sıcaklığı, rüzgar hızı, bağıl nem, hava basıncı, bulutluk ve yağış miktarı gibi hava değişkenlerine bağlıdır. Güneş enerjisi üretimi, verimli kullanımı zor bir iştir ve güç zamana göre değiştiği için büyük dikkat gerektirir. Bunun üstesinden gelmek için, gelecekteki enerji üretimi iyi tahmin edilmelidir. Elektrik şebekesinin yönetimi ve güneş enerjisi ticareti için tahmin bilgileri gereklidir [30]. Tahmin yöntemleri üç farklı metoda ayrılabilir: Fiziksel, istatistiksel ve hibrid yöntemler. Fiziksel yöntem, sıcaklık, basınç ve bulut örtüsü gibi fiziksel verileri kullanarak sayısal hava tahmini ve atmosfere dayanır. İstatistiksel metod, modelleri eğitmek için geçmiş verileri kullanır ve matematiksel bir model olarak kabul edilir. Hibrid metod, fiziksel ve istatistiksel yaklaşımların bir kombinasyonudur [16]. Bir tahmin yöntemi ve modelin seçimi, mevcut bilgilere, gerekli çözünürlüğe, doğruluğa ve amaca (çok kısa, kısa ve uzun vadeli tahminlere) bağlıdır. Çok kısa vadeli veya gün içi tahminleri, 6 saat öncesine kadar olan tahminlerle ilgilidir. Kısa vadeli tahmin, önümüzdeki 7 gün öncesine kadar tahminler sağlar. Uzun vadeli tahmin genellikle yıllık tahmini ifade eder ve stratejik planlama için gereklidir [31]. Aşağıdaki alt bölümlerde, farklı tahmin metotları hakkında ayrıntılı bilgi verilmektedir.

3.1.1. Fiziksel Metodlar

Fiziksel metodlar, atmosferin fiziksel durumunu ve dinamik hareketi tanımlayan matematiksel denklemlere dayanmaktadır. Bu yaklaşım, küresel yatay ışınım, ortam sıcaklığı, nispi nem, rüzgar hızı ve sistem konumu, tarihsel veriler veya sistem özellikleri gibi farklı veriler ile hava tahminlerini kullanır [31]. Fiziksel metodların uzun vadeli tahminler için kullanışlı olduğu gösterilmiştir. Şu anda, fiziksel temelli tahmin,

esas olarak, sayısal hava tahmini ve uydu veya Total Sky Imager (TSI) tarafından yapılan bulut gözlemleri kullanılarak gerçekleştirilmektedir [14].

3.1.1.1. Sayısal Hava Tahmini (NWP)

Sayısal hava tahmini (Numerical Weather Prediction, NWP) atmosferin fizikine dayanır. NWP, hava durumu gözlemlerini kullanır ve süper bilgisayarları kullanarak gelecekteki hava durumunu tahmin etmek için bu verileri işler. NWP sonraki bir gün ya da çok gün için çok kullanılabilir. Yeryüzünde güneş ışınımının önündeki en büyük engeller olarak görülen bulutlardaki geçici değişimler NWP'de tahmin edilmektedir. Saat başı tahminde yüksek zamansal ve mekansal çözünürlüğü elde etmek için NWP ve uydu tahminleri şu anda yetersizdir. Bir gökyüzü görüntüleyicisi kullanarak yer gözlemleri, bu tahmin boşluğunu doldurma fırsatı sunar ve büyük ölçekli bir PV enerji santraline yada kentsel bir dağıtım besleyicisine bulut gölgelerinin kilometrekarelik görüntüsünü sağlar [14].

3.1.1.2. Uydu ve Bulut Görüntü Modelleri

Fiziksel temelli tahminler için, bulut örtüsü ve bulut optik derinliği güneş ışınlarını etkileyen en önemli parametrelerdir [16]. Uydu ve bulut görüntülerine dayalı model, bulutları analiz eden fiziksel bir tahmin modelidir. Uydu ve bulut görüntüleri, bulutları karakterize etmek ve değişkenliklerini tespit etmek için işlenir. Bu model, daha önce kaydedilen zaman adımlarında bulut yapılarını belirleyerek çalışır. Bulutların yapısını ve konumlarını anlamak güneş ışınımını tahminde yardımcı olur. Düşük güneş yüksekliği, düşük ışınımın koşulları ve yüksek mekansal değişkenlik altında, uydu ve bulut görüntülerinin hataları önemli ölçüde artabilir [14].

3.1.2. İstatistiksel Metod

İstatistiksel tahmin yöntemi, geçmişteki verileri kullanarak gelecekteki değerleri tahmin eden matematiksel bir modeldir. Verilerdeki düzen ve eğilimleri tespit etmek için matematiksel denklemleri kullandığı için istatistikî model olarak adlandırılır. Güneş enerji santralinin gelecekteki enerji üretimini tahmin etmek için, güneş enerji santrali gücünün geçmiş verileri çıktı olarak alınır ve girdiler için, yer istasyonu veya uydu verileri, hava durumu verileri (sıcaklık, küresel güneş radyasyonu, güneşlenme süresi, rüzgar hızı, nispi nem, bulutluluk örtüsü ve ortalama yağış) gibi çeşitli değişkenlerin

geçmiş verileri kullanılır. Güneş enerjisi üretiminin tahmininde istatistiksel yöntemde kullanılan modeller, çoklu doğrusal regresyonlar, sinir ağları (SA), destek vektör makineleri (SVM), otoregresif hareketli ortalama (ARMA), otoregresif entegre hareketli ortalama (ARIMA) ve otoregresif (entegre) hareketli ortalama dış girdi modeli gibi modellerdir (ARIMAX) [5, 31].

3.1.2.1. Otoregresif Hareketli Ortalama (ARMA) Modeli

Box-Jenkins modeli (1976) olarak da bilinen ARMA modeli, istatistiksel yöntemde zaman serisi modellerinin bir türüdür. İki kısımdan oluşur. Biri otoregresif (AR) diğeri ise hareketli ortalama (MA) kısmıdır. Matematiksel olarak ARMA modeli aşağıdaki şekilde ifade edilmiştir:

$$Y(t) = \sum_{i=1}^p a_i Y(t-1) + \sum_{j=1}^q b_j e(t-1) \quad (8)$$

$Y(t)$, AR kısmında t zamanındaki tahmin edilen değerdir, p AR kısmın derecesi ve a_i AR kısmın katsayısı, MA kısmında, q MA kısmın derecesi ve b_j MA kısmın katsayısı. $e(t)$ sıfır ortalamalı ve sabit varyanslı rastgele ilişkisiz değişkenler üreten beyaz gürültüdür. ARMA modeli, matematiksel olarak ARMA (p, q) ile gösterilir; burada p ve q sırasıyla AR ve MA derecesidir. ARMA (p, q), q sıfır ise AR (p) modeline ve p sıfır ise MA(q) modeline dönüştürülebilir. ARMA modeli genellikle otokorelasyon zaman serisi verilerine uygulanır. ARMA modelleri çok esnektir çünkü farklı dereceleri kullanarak farklı zaman serilerini temsil edebilirler. Zaman serilerinde doğrusal korelasyon yapısı olduğunda tahminde yetkin oldukları kanıtlanmıştır. ARMA modeli, sabit zaman serilerinde iyi performans gösterir ve gelecekteki değerleri tahmin etmek için iyi bir araçtır [32, 33, 34].

3.1.2.2. Otoregresif Entegre Hareketli Ortalama (ARIMA) Modeli

ARIMA, zaman serisinin gelecekteki değerini tahmin etmek için kullanılan başka popüler bir zaman serisi modelidir. ARMA modeli ile ARIMA modeli arasındaki fark, ARIMA modelinin üç kısımdan oluşmasıdır. AR kısmı, MA kısmı ve entegre süreç (farklılaştırmış süreç olarak da bilinir). ARIMA modelleri, ilk önce ARIMA'nın entegre süreci tarafından sabit seriye dönüştürülen sabit olmayan zaman serilerinde kullanılır. Matematiksel olarak ARIMA modeli aşağıdaki denklem ile ifade edilir.


$$(1 - \sum_{i=1}^p a_i L^i)(1 - L)^d Y(t) = (1 + \sum_{j=1}^q b_j L^j) e(t) \quad (9)$$

L lag operatörüdür ve $LY(t) = Y(t-1)$ ile tanımlanır. $Y(t)$, AR kısmında, t zamanındaki tahmin edilen değer, p AR kısmın derecesi ve a_i AR kısmın katsayısı, veya hareketli ortalama kısmında q MA kısmın derecesi ve b_i MA kısmın katsayısı. $e(t)$ sıfır ortalamalı ve sabit varyanslı rastgele ilişkisiz değişkenler üreten beyaz gürültüdür. Son olarak d mevsimlik olmayan farklılıkların sayısıdır. d sıfır olduğu durumda, ARIMA (p, d, q) ARMA (p, q) modeline eşittir. ARIMA modelinde, zaman serisinin tahmin edilen gelecek değeri, geçmiş değerlerin ve geçmiş hataların doğrusal bir birleşimi olarak ifade edilir [34, 35].

3.1.2.3. Yapay Sinir Ağları

Yapay sinir ağı, kompleks gerçek problemleri modellemek için, insan beynindeki biyolojik sinir sistemi şeklinde çalışma fikrine dayanan bir istatistiksel yöntemdir. YSA, yapay zekanın temelidir ve insan veya istatistiksel standartlar tarafından imkansız veya zor olan problemleri çözer.

YSA, daha fazla verilerle edildikçe daha iyi sonuçlar üreten kendi kendine öğrenme yeteneklerine sahiptir. Sinir ağları modeli, girdiler ve çıktılar arasındaki karmaşık ilişkileri anlamak ve bunlar arasındaki veri düzenlerini bulmak için kullanılan, doğrusal olmayan bir istatistik yöntem olarak değerlendirilir. YSA'ların karakteristik özellikleri, doğrusal olmayan, yüksek paralellik, hata ve gürültüye tolerans ve öğrenme ve genelleme yetenekleridir. İnsan beyni gibi, yapay sinir ağlarında nöron düğümleri birbirine bağlı olarak yapılırlar. İnsan beyninde nöronlar diye adlandırılan milyonlarca hücre bulunur. Her nöron beyinden bilgi (girdi) ve uzağa çıktılar taşıyarak bilgi işlemeden sorumlu bir hücre gövdesinden oluşur. YSA, düğümlerle birbirine bağlanan işlem birimleri olarak adlandırılan binlerce yapay nöron oluşturmaktadır. İşlem birimleri giriş ve çıkış ünitelerinden oluşur. Giriş, iç ağırlıklandırma sistemine dayalı çeşitli formları ve bilgi yapıları alır ve sinir ağı, çıktı raporu üretmek için elde edilen bilgileri öğrenmeye çalışır. YSA, 3 kademedен oluşur: girdi, kapalı kutu ve çıktı [12, 36].




Şekil 3.1: m Girişli YSA

Nöron girdi sinyalleri, ilgili ağırlıkları ile çarpılır ve sonra toplama noktasına beslenir. Ağ girişini oluşturmak için nöronda ağırlıklı girdilerle toplanan bir yanlılık vardır ve sonuç, çıktı üretmek için aktivasyon işlevine işlenir.

3.1.2.3.1. Yapay Sinir Ağlarının Mimari Yapısı

Tek Katmanlı İleri Beslemeli Mimari Yapı

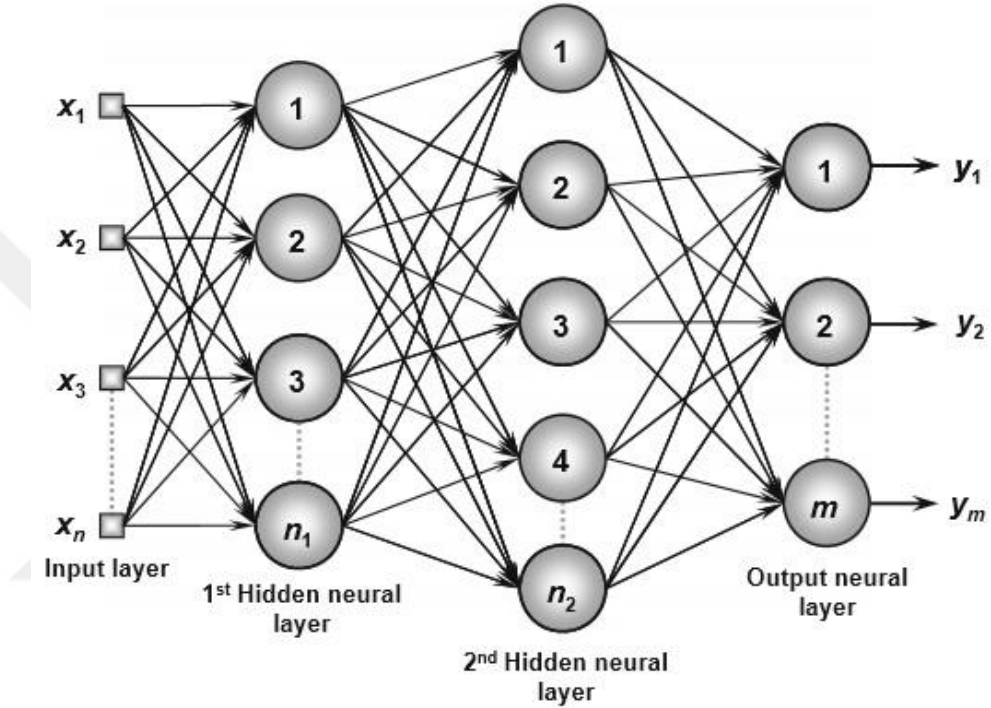
Bu YSA'da sadece bir giriş katmanı ve aynı zamanda çıktı katmanı olan tek bir sinir katmanı vardır. Bilgi akışı her zaman girdi katmanından çıktı katmanına tek bir yönde olur.



Şekil 3. 2: Tek Katmanlı İleri Besleme Ağı

Çok Katmanlı İleri Beslemeli Mimari Yapı


Çoklu katmanlı ileri beslemeli ağlar bir veya daha fazla gizli katmandan oluşur. Gizli katmanların sayısı ve ilgili nöron miktarı, ağ tarafından eşleştirilen sorunun doğasına ve karmaşıklığına ve aynı zamanda soruna ilişkin mevcut verilerin niceliğine ve kalitesine bağlıdır.



Şekil 3. 3: Çok Katmanlı İleri Beslemeli Ağı

Geri Beslemeli (Tekrarlayan) Mimari Yapı

Bu ağlarda, nöronların çıktıları diğer nöronlara geribildirim girdileri olarak kullanılır. Çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Geribildirim özelliği, bu ağların dinamik bilgi işleme için nitelikli olmasını sağlar. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur [37].



Şekil 3. 4: Geri Beslemeli Ağ

3.1.2.3.2. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında öğrenme süreci, ağdaki nöronlar arasındaki ağırlık bağlantılarını ayarlayarak gerçekleştirilir. Yapay sinir ağları eğitiminde kullanılabilen ve öğrenme algoritması olarak adlandırılan farklı algoritmalar vardır. YSA'larda öğrenme süreci, öğrenme algoritmasıyla ağın ağırlıklarının değiştirilmesinin bir sonucudur. Öğrenmenin amacı, ağın anlamlı bir çıktı üretmesini sağlayan ağırlık seti bulmaktır. Ağ girişleri ve çıktılar arasındaki ilişkiyi öğrendikten sonra, çözümleri genelleştirir, bu da ağın herhangi bir girdi değerinden beklenen (veya istenen) çıktısına yakın bir çıktı üretebileceği anlamına gelir [37].

Denetimli öğrenme

YSA, sinir ağını eğitirken istenen çıktı girdiyle sağlanırsa denetimli öğrenme algoritması kullanır. YSA modeli, hedef çıktıya göre ağırlıklarını güncelleyerek ağı düzeltir.

Denetimsiz Öğrenme

Denetimsiz öğrenme algoritması, sadece girdiler verildiğinde ve yapay sinir ağı modeli, herhangi bir dış yardım olmadan ilişki bulduğunda kullanılır.

Takviyeli öğrenme

Takviyeli öğrenme, denetimli öğrenmeye benzer. Bir hedef çıktı sağlamak yerine, bu öğrenme yaklaşımında ağın her iterasyonu sonucunda elde ettiği sonucun iyi veya kötü

olup olmadığına dair bilgi verilir. Ağ bu bilgilere göre kendini yeniden düzenler. Takviyeli öğrenme tarafından kullanılan çeşitli öğrenme algoritmaları, yeterli sonuçlar üretme şansları varsa güçlendirilebilecek olası çözümlerin sınırlı bir setini düşünerek, olasılıksal olarak ayarlama eylemlerini seçen stokastik yöntemlere dayanır.

3.1.2.4. Doğrusal Olmayan Özbağlanımlı Dış Girdili Ağ Modeli

Doğrusal Olmayan Özbağlanımlı Dış Girdili Ağ Modeli (Non-linear AutoRegressive network with eXogenous input, NARX), içindeki geribesleme bağlantıları ile tekrarlayan bir YSA türüdür. NARX model terminolojisi, zaman serisi modellemesinde sıklıkla kullanılan doğrusal ARX modeline dayanmaktadır. NARX modeli için tanımlama denklemi aşağıdadır.

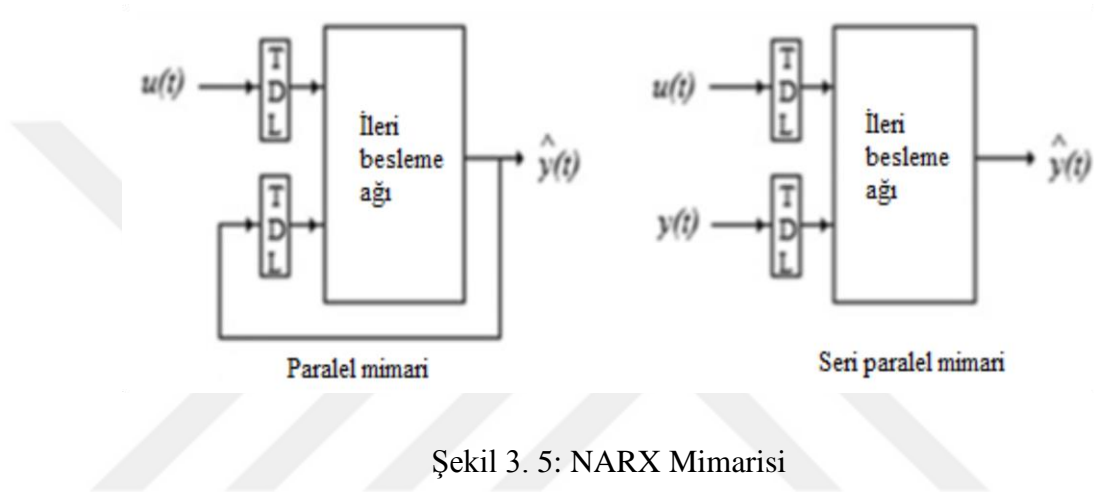
$$y(t) = f\left(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)\right) + e(t) \quad (10)$$

Burada $y(t)$ hedef çıktıdır ve $y(t-1), \dots, y(t-n_y), u(t-1), \dots, u(t-n_u)$ sırasıyla hedef çıkışının ve harici girdinin ayrılma zamanı t 'deki geçmiş değerleridir. Ayrıca $n_y \geq 1, n_u \geq 1, n_u \leq n_y$ girdi belleği ve çıktı belleği sıralarıdır ve $e(t)$, genellikle Gauss ve beyaz olarak kabul edilen bir gürültü terimidir. Doğrusal olmayan haritalama fonksiyonu $f(\cdot)$ Genellikle bilinmemektedir ve yaklaşık alınabilir. Oluşan bağlantı mimarisine NARX ağı denir. Bu özel model, doğrusal olmayan dinamik davranış modellemesi için oldukça uygundur ve çeşitli uygulamalarda yoğun şekilde kullanılmaktadır. Diğer doğrusal olmayan otoregressif ağların aksine; NARX ağları yalnızca hedef değişken değil diğer değişkenleri içerecek şekilde geliştirilmiştir. Modeldeki X kısmı, dış kaynak değerleridir; diğer harici parametreleri de modele dahil edilmiştir. Çıktı $y(t)$, çıkışın daha önceki değerlerine ve önceki giriş değerlerine göre sağlanır. NARX ağı, ileri beslemeli sinir ağı mimarisi kullanılarak f fonksiyonunun yaklaşığı için uygulanır [1, 2, 3, 8].

3.1.2.4.1. NARX Ağı Mimarisi

Tekrarlayan ağda, çıkış, sadece ağa yapılan geçerli girişe değil ağın önceki giriş ve çıkışlarına da bağlıdır. Bağımlı çıktı $y(t)$ 'nin sonraki değeri, bağımsız (dış kaynak) girişin daha önceki değerlerin üzerinde gerilemektedir. NARX ağının çıktısı, modellenmekte olan bazı doğrusal olmayan dinamik sistemin çıktılarının bir tahmini

olarak kabul edilebilir. Çıktı, paralel mimari olarak adlandırılan standart NARX mimarisinin bir parçası olarak ileri beslemeli ağın girişine geri beslenir. Bununla birlikte, bazı teknikleri, hedef çıktıyı kendisi bir girdi olarak beslemeyi içerir, bu da daha iyi ağ optimizasyonunu sağlar. Döngü, her zaman tahmini çıkışı sürekli olarak ağa geri getirmek için gerekli olup ağın standart ileri beslemeli geri yayılım (Feed Forward Back Propagation, FFBP) mimarisine gerçekleşmesine yardımcı olmaktadır. Bu işlem, seri paralel mimari olarak adlandırılan NARX ağını verir [38, 39].



Şekil 3. 5: NARX Mimarisi

3.1.2.5. Eğitim Algoritmaları

Bir ağ yapılandırıldıktan sonra, ağın eğitilmesi gerekir. Eğitim sürecini başlatmak için başlangıç ağırlıkları rastgele seçilir. Eğitim sürecinde, ağ, sinaptik ağırlıkların uyarlanması yoluyla öğrenip bu şekilde istenen çıktı ile gerçek çıktı arasındaki farkı azaltır [40]. Aşağıdaki alt bölümlerde eğitim algoritmalarından Dik İniş Algoritması, Network Yöntemi, Gauss-Network Algoritması ve Levenberg-Marquardt Algoritması anlatılacaktır.

3.1.2.5.1. Dik İniş Algoritması

Dik iniş algoritması, Hata Geri Yayılım (EBP) algoritması olarak da bilinir. Geri yayılım algoritması, ağ çıkışı ile istenen değer arasındaki toplam kare hatayı en aza indirmek için gradyan inişi gerçekleştirir. Tüm desenler ve tüm çıkışlar için toplam hata, aşağıdaki denklemle verilir:

$$E(x, w) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \quad (11)$$

Burada P , eğitim desenleri sayısıdır, M , çıkış sayısı, x , giriş vektörü, w ağırlık vektörü ve $e_{p,m}$ m çıkışında p eğitim deseninin eğitim hatasını tanımlar. $e_{p,m}$ şu şekilde verilir:

$$e_{p,m} = d_{p,m} - o_{p,m} \quad (12)$$

Burada d istenen çıkış ve o gerçek çıkıştır.

Dik iniş algoritması, ağ ağırlıklarını güncelleyerek istenen çıkış ile gerçek ağ çıkış arasındaki farkı en aza indirmek için toplam hatanın birinci derece farklılaştırmasını kullanır. Yeni güncellenen ağırlık şu şekilde verilir:

$$w_{k+1} = w_k + \alpha g_k \quad (13)$$

Burada α öğrenme sabiti ve g toplam hata farkı ile tanımlanan gradyandır. g , aşağıda denklemlerle tanımlanır:

$$g = \frac{\partial E(x,w)}{\partial w} = \left[\frac{\partial E}{\partial w_1} \frac{\partial E}{\partial w_2} \dots \dots \frac{\partial E}{\partial w_N} \right]^T \quad (14)$$

Gradyan vektörünün elemanları çok küçüktür ve çok küçük bir ağırlık değişimine neden olur. Dik iniş algoritmasının eğitim süreci asimtotik yakınsaklıktır [42].

3.1.2.5.2. Newton Yöntemi

Newton yöntemi, tüm gradyan bileşenlerinin (g_1, g_2, \dots, g_N) ağırlığın fonksiyonu olduğunu ve tüm ağırlıkların doğrusal olarak bağımsız olduğunu varsayar ve ilişki aşağıdaki eşitlik ile verilir:

$$g_i \cong g_i(0) + \frac{\partial g_i}{\partial w_1} \Delta W_1 + \frac{\partial g_i}{\partial w_2} \Delta W_2 + \dots + \frac{\partial g_i}{\partial w_j} \Delta W_j + \dots + \frac{\partial g_i}{\partial w_N} \Delta W_N \quad (17)$$

Burada $i=1, 2, \dots, N$ ve $j=1, 2, \dots, N$

Denklem (14)'ten:

$$\frac{\partial g_i}{\partial w_j} = \frac{\partial \frac{\partial E}{\partial w_i}}{\partial w_j} = \frac{\partial^2 E}{\partial w_i \partial w_j} \quad (18)$$

Denklem (17) ve denklem (18) birleştirilerek, gradyan yaklaşımının i 'inci kısmı:

$$g_i \cong g_i(0) + \frac{\partial^2 E}{\partial w_i \partial w_1} \Delta W_1 + \frac{\partial^2 E}{\partial w_i \partial w_2} \Delta W_2 + \dots + \frac{\partial^2 E}{\partial^2 w_i} \Delta W_i + \dots + \frac{\partial^2 E}{\partial w_i \partial w_N} \Delta W_N \quad (19)$$

olur.

Toplam hata fonksiyonu E^3 'nin minimum noktasını elde etmek için, gradyan vektörünün her bir elemanı sıfır olmalıdır. Bu durumda, denklem (19) şöyle olmaktadır:

$$0 = g_i(0) + \frac{\partial^2 E}{\partial w_i \partial w_1} \Delta W_1 + \frac{\partial^2 E}{\partial w_i \partial w_2} \Delta W_2 + \dots + \frac{\partial^2 E}{\partial^2 w_i} \Delta W_i + \dots + \frac{\partial^2 E}{\partial w_i \partial w_N} \Delta W_N \quad (20)$$

Gradyan vektörünün tüm bileşenleri aşağıdaki şekilde elde edilebilir:

$$\begin{cases} -g_1 = \frac{\partial^2 E}{\partial w_1 \partial w_1} \Delta W_1 + \frac{\partial^2 E}{\partial w_1 \partial w_2} \Delta W_2 + \dots + \frac{\partial^2 E}{\partial w_1 \partial w_N} \Delta W_N \\ -g_2 = \frac{\partial^2 E}{\partial w_2 \partial w_1} \Delta W_1 + \frac{\partial^2 E}{\partial w_2 \partial w_2} \Delta W_2 + \dots + \frac{\partial^2 E}{\partial w_2 \partial w_N} \Delta W_N \\ \dots \dots \dots \\ -g_N = \frac{\partial^2 E}{\partial w_N \partial w_1} \Delta W_1 + \frac{\partial^2 E}{\partial w_N \partial w_2} \Delta W_2 + \dots + \frac{\partial^2 E}{\partial w_N \partial w_N} \Delta W_N \end{cases} \quad (21)$$

Matris notasyonu ile denklem (21) şöyle olmaktadır:

$$\begin{bmatrix} -g_1 \\ -g_2 \\ \dots \\ -g_N \end{bmatrix} = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1 \partial w_1} & \frac{\partial^2 E}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_1 \partial w_N} \\ \frac{\partial^2 E}{\partial w_2 \partial w_1} & \frac{\partial^2 E}{\partial w_2 \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_2 \partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial^2 E}{\partial w_N \partial w_1} & \frac{\partial^2 E}{\partial w_N \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_N \partial w_N} \end{bmatrix} X \begin{bmatrix} \Delta W_1 \\ \Delta W_2 \\ \dots \\ \Delta W_N \end{bmatrix} \quad (22)$$

İkinci derece türev matrisine Hessian matrisi denir ve şu şekilde elde edilir:

$$H = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1 \partial w_1} & \frac{\partial^2 E}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_1 \partial w_N} \\ \frac{\partial^2 E}{\partial w_2 \partial w_1} & \frac{\partial^2 E}{\partial w_2 \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_2 \partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial^2 E}{\partial w_N \partial w_1} & \frac{\partial^2 E}{\partial w_N \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_N \partial w_N} \end{bmatrix} \quad (23)$$

Denklemler (22) ve (23) birleştirilmesiyle ve Newton'un yöntemi ile gradyan için genelleştirilmiş denklem şöyledir:

$$-g = H \Delta W \quad (24)$$

Yani ağırlık değişimi $\Delta W = -H^{-1}g$ 'dir bu nedenle, Newton'un yöntemi için güncelleme kuralı şöyledir:

$$w_{k+1} = w_k - H_k^{-1}g_k \quad (25)$$

Toplam hata fonksiyonunun ikinci dereceden türevi olarak, Hessian matrisi H gradyen vektörünün değişimi üzerine değerlendirmeyi verir. Dik iniş yöntemi ile karşılaştırıldığında, toplam hata fonksiyonunun ikinci derece türevleri gradyan vektörünün her bileşeni için hesaplanmalıdır. Newton'un yöntemi ağırlık güncellemeye uygulanırsa, Hessian matrisi H' 'yi elde etmek için toplam hata fonksiyonunun ikinci dereceden türevleri hesaplanmalıdır ve bu, çok karmaşık olabilir [41, 42].

3.1.2.5.3. Gauss-Newton Algoritması

Newton'un yönteminde olduğu gibi, ağırlığın güncellenmesi Hessian matrisi H' 'nin hesaplanmasını gerektirir ve karmaşıktır. Hesaplamayı basitleştirmek için, Jacobian matrisi aşağıdaki gibi tanıtlır:

$$J = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \frac{\partial e_{1,1}}{\partial w_2} & \dots & \frac{\partial e_{1,1}}{\partial W_N} \\ \frac{\partial e_{1,2}}{\partial w_1} & \frac{\partial e_{1,2}}{\partial w_2} & \dots & \frac{\partial e_{1,2}}{\partial W_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1,M}}{\partial w_1} & \frac{\partial e_{1,M}}{\partial w_2} & \dots & \frac{\partial e_{1,M}}{\partial W_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,1}}{\partial w_1} & \frac{\partial e_{P,1}}{\partial w_2} & \dots & \frac{\partial e_{P,1}}{\partial W_N} \\ \frac{\partial e_{P,2}}{\partial w_1} & \frac{\partial e_{P,2}}{\partial w_2} & \dots & \frac{\partial e_{P,2}}{\partial W_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,M}}{\partial w_1} & \frac{\partial e_{P,M}}{\partial w_2} & \dots & \frac{\partial e_{P,M}}{\partial W_N} \end{bmatrix} \quad (26)$$

Jacobian J matrisi ve gradyan vektörü arasındaki ilişki şöyledir:

$$g = Je \quad (27)$$

Ve hata vektörü e şu şekildedir:

$$e = \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ \dots \\ e_{1,M} \\ \dots \\ e_{P,1} \\ e_{P,2} \\ \dots \\ e_{P,M} \end{bmatrix} \quad (28)$$

Hessian matrisi H ve Jacobian matris J arasındaki ilişki şu şekilde yeniden yazılabilir:

$$H = J^T J \quad (29)$$

Denklemler (27) ve (29)'daki Jacobian matrisi açısından gradyan vektörünün ve Hessian matrisinin gösterimini kullanarak, Gauss-Newton algoritması için ağırlık güncelleme kuralı şu şekildedir:

$$w_{k+1} = w_k - (J_k^T J_k)^{-1} J_k e_k \quad (30)$$

3.1.2.5.4. Levenberg-Marquardt Algoritması

Levenberg-Marquardt algoritması, her zaman tersine çevrilebilir olduğundan emin olmak için Hessian matrisine bir başka yaklaşımı tanıtır. Levenberg-Marquardt algoritması yaklaşımı şu şekilde tanımlanmıştır:

$$H = J^T J + \mu I \quad (31)$$

μ her zaman pozitifdir. I birim matrisidir ve kombinasyon katsayısı olarak adlandırılır. Bu yaklaşımla, yaklaşık Hessian matrisinin ana diyagonalinin elemanları sıfırdan büyük olacaktır. Bu nedenle, matris H 'nin daima ters çevrilebilir olduğundan emin olunur. Levenberg-Marquardt algoritmasının ağırlık güncelleme kuralı şu şekilde temsil edilmektedir:

$$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k \quad (32)$$

Levenberg-Marquardt algoritmasının, eğitim sürecini Dik İniş ve Gauss-Newton algoritmaları sağlar. μ çok küçük olduğunda, yani sıfıra yakın olduğunda Gauss-Newton algoritması kullanılır ve büyük olunca Dik İniş algoritması kullanılır [41, 42]. Tablo 2'de farklı algoritmaların özellikleri verilmiştir.

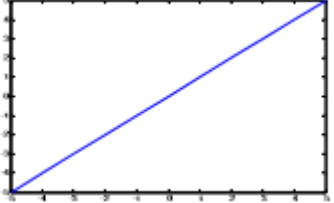
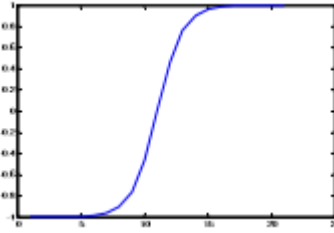
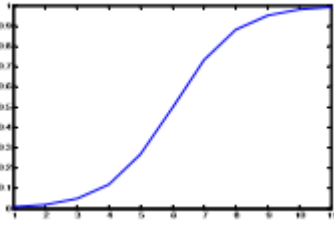
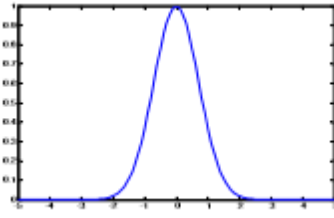
Tablo 2: Farklı Algoritmaların Özellikleri

Algoritma	Güncelleme kuralı	Yakınsama	Hesaplamalı karmaşıklığı
EBP	$w_{k+1} = w_k + \alpha g_k$	Kararlı, yavaş	Gradyent
Newton	$w_{k+1} = w_k - H_k^{-1} g_k$	Kararsız, hızlı	Gradyent ve Hessian
Gauss-Newton	$w_{k+1} = w_k - (J_k^T J_k)^{-1} J_k e_k$	Kararsız, hızlı	Jacobian
Levenberg-Marquardt	$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k$	Kararlı, hızlı	Jacobian

3.1.2.6. Transfer Fonksiyonu

Transfer fonksiyonu, aktivasyon fonksiyonu olarak da bilinir; sinir ağ modeli çıkışının genliğini kontrol eder. Transfer fonksiyonu, giriş sinyallerini çıkış sinyallerine çevirir. Sık kullanılan transfer fonksiyonları sigmoid (lojistik ve hiperbolik teğet), doğrusal ve Gauss'dur. Sigmoid (lojistik ve hiperbolik teğet) fonksiyonunun türevi bulunması kolay olduğundan dolayı diğerlerinden daha çok kullanılır. Genellikle, bu fonksiyonlar ağın gizli katmanında uygulanır [9,40]. Tablo 3'te MATLAB yazılımında bulunan Yerleşik Transfer Fonksiyonları gösterilmektedir.

Tablo 3. MATLAB Yerleşik Transfer Fonksiyonları [9]

Fonksiyon adı	Matematik denklemi	Grafiği
Doğrusal	$f(x) = x$	
Hiperbolik Teğeti Sigmoid	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
Lojistik Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	
Gaussian	$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	

3.2. Performans Değerlendirmesi

Geliştirilen modellerin performansını kantitatif olarak değerlendirmek için istatistiksel analiz yapılmalıdır [9]. Modern güç şebeke sistemi PV güç sisteminden önemli miktarda elektrik aldığından, güneş enerjisinin şebeke entegrasyonu için şebeke sistemlerinin kararlılığı, PV güç sistemlerinin ünite taahhüdüne büyük ölçüde bağımlı olmuştur. Şebeke sistemi, taahhütlü elektrik sağlamazsa, yeterli elektrik beslemesi sağlamak açısından zorluklarla karşılaşmaktır. Bu nedenle, PV güç üretiminin doğru tahmini, şebeke stabilitesinin sağlanması için önemlidir. Böylece, PV güç tahmin modelinin doğruluk ölçümü, tahmin sürecinin etkili bir parçasıdır [1]. Normalize edilmiş kare ortalama kök hatası (nRMSE), ortalama sapma hatası (MBE), ortalama mutlak hata

(MAE) ve ortalama mutlak yüzde hatası (MAPE) içeren istatistiksel analiz, tahmin modelinin performansını değerlendirmek için kullanılabilir. nRMSE, ölçülen veriler etrafındaki belirlenmiş değerlerin varyasyonunun bir ölçüsü olan kısa vadeli performans hakkında bilgi sağlar. nRMSE ne kadar düşüğe, tahmin o kadar daha doğrudur. MBE, tahmin edilen değerlerin ilgili ölçülen verilerden ortalama sapmasının bir göstergesidir ve modellerin uzun vadeli performansı hakkında bilgi sağlayabilir. Daha düşük MBE, daha iyi uzun vadeli model tahminidir. Bir pozitif MBE değeri, aşırı tahmin miktarını ve tersini gösterir. MAPE, tahmin modellerinin performansında yüzde olarak hesaplandığı için yaygın olarak kullanılmaktadır. MAPE sonuçlarının yorumu, modelin ne kadar doğru olduğunu göstermektedir. %10'dan daha az hata yüksek bir doğru tahmini, %11 ile %20 arasında hata iyi bir tahmini, %21 ile %50 arasında hata güvenilir bir tahmini, %51 veya daha fazlası ise yanlış bir tahmini gösterir. MAE sadece mutlak hataların ortalamasıdır. Mutlak hata, öngörülen değer ile gerçek değer arasındaki farkın mutlak değeridir. MAE, bir tahminin ortalamadan tahmin edeceğimiz bir hatanın ne kadar büyük olduğunu gösterir [9, 44]. Yukarıda belirtilen istatistiksel parametrelerin ifadeleri aşağıdadır:

$$nRMSE = \left(\sqrt{\frac{1}{N} \sum_{i=1}^N (Wf - Wt)^2} \right) * \frac{100}{Wt(max)} \quad (33)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (Wf - Wt) \quad (34)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|Wf - Wt|}{Wt} * 100\% \quad (35)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Wf - Wt| \quad (36)$$

Burada, Wf , Wt ve $Wt(max)$, sırasıyla zaman noktasında öngörülen değeri, gözlenen/ölçülen değeri ve maksimum gözlemlenen değeri temsil eder. N , zaman ölçeğine ait veri örneğinin sayısıdır.

4. BÖLÜM

MODEL TASARIMI VE YÖNTEMİ

4.1. Veri Toplanması

PV güneş enerjisi sistemlerinde, güneş enerjisi santralinden üretilen güç miktarı çeşitli faktörlere bağlıdır. Güneş enerjisi üzerinde etkisi olan faktörlerden bazıları hava değişkenleridir. Önerilen modelde, hava değişkenleri, güneş enerjisi santrali tarafından üretilen gücün tahmin edilmesi için bağımlı faktörler olarak kullanılmıştır. Ayrıca, göz önünde bulundurulmuş yerin güneş saat açısı ve zenit açısı hesaplanıp modelin girdilerine eklenmiştir. Güneş enerjisi sadece gün boyunca mevcuttur, gece boyunca güneş santralinden enerji üretimi yoktur. Göz önüne alınan güneş santrali, Kayseri ilinin Bünyan ilçesinde, $38^{\circ}40'29.84''N$ ve $36^{\circ}00'38.49''E$ coğrafi koordinatlarındadır. Seçilen santral, aynı lokasyonda bulunan diğer güneş santrallerinden biridir ve Şekil 4.1'de ERCIYES 4 GES olarak etiketlenmiştir. Şekilde işaretli alan, dikkate alınan güneş enerjisi santralinin yukarıdan görüntüsüdür.



Şekil 4.1 Güneş Enerji Santrali Lokasyonu

Orman ve Su İşleri Bakanlığı Meteoroloji Genel Müdürlüğü tarafından yetkilendirilen Bünyan ve Pınarbaşı meteoroloji istasyonlarından meteorolojik verileri toplanmıştır. Toplanan geçmiş meteorolojik veriler, modele dış girdiler olarak verilir. Güneş enerjisi santrali tarafından üretilen gücün geçmiş verileri, santralden sorumlu şirket (Hunat Enerji) tarafından sağlanır ve hedef veri olarak kullanılır. Meteorolojik veriler için Haziran 2016 - Ağustos 2017 dönemi ve güneş enerjisi santrali verileri için Haziran 2016 - Temmuz 2017 dönemi alınmıştır. Modeldeki meteorolojik veriler, saatlik küresel güneş radyasyonu, güneş ışınlam şiddeti, ortalama sıcaklık, minimum sıcaklık, maksimum sıcaklık, rüzgar hızı, bağıl nem, hava basıncı ve yağış miktarıdır. Tablo 4, toplanan değişkenlerin kısaltmaları ve birimlerini ile göstermektedir.

Tablo 4: Toplanan Veri Parametrelerinin Listesi

	Değişken	Kısaltma	Birim
1	Üretilen güneş enerjisi	OUTP	kW
2	Küresel güneş radyasyonu	GSR	Wathour/m ²
3	Güneş ışınlam şiddeti	SSI	Cal/cm ²
4	Ortalama sıcaklık	TMP	°C
5	Minimum sıcaklık	MNT	°C
6	Maksimum sıcaklık	MXT	°C
7	Rüzgar hızı	WDS	m/s
8	Bağıl nem	RLH	%
9	Hava basıncı	PRS	hPa
10	Yağışmıktarı	PRC	mm

4.2. Veri Ön İşleme

Modelin doğru çalışabilmesi için veriler üzerinde ön işlemlere ihtiyaç duyumaktadır. Aşağıdaki alt bölümlerde, modelde kullanılmadan önce veriler üzerinde yapılan hazırlıklar anlatılmıştır.

4.2.1. Veri Düzenleme

Gerekli tüm veriler, toplandıktan sonra, kullanımdan önce düzenlenmiştir. MS Excel ve Matlab programlarını kullanılarak, veriler bir tablo halinde düzenlenmiştir. Tablo sütunları meteorolojik verileri, saat açısı, zenit açısı ve üretilen gücün geçmiş verilerinden oluşmaktadır. Veri tablosunun her satırı, her değişkenin saatlik değerini içerir. Doğru olması için meteorolojik veriler ve güç verileri Kayseri ilindeki gün doğumu ve gün batımı zamanı ile senkronize edilmiştir [40]. Veri düzenlemesinden

sonra özet olarak, veri tablosu 16 sütundan oluşur: zaman ve tarih için 4 sütun (yıl, ay, tarih, günün saati), meteorolojik değişkenler için 9 sütun, saat açısı, zenit açısı ve üretilen güç için birer sütun. Rüzgar verileri için sadece rüzgar hızı kullanılmıştır.

4.2.2. Veri Temizleme

Eksik Verilerin Yönetimi

Toplanan verilerde, dikkate alınması gereken eksik veriler bulunmaktadır. Bunlar modelin performansına katkıda bulunabilecek önemli bilgiler içerir. Bu çalışmanın bir parçası olarak, eksik verilerin model performansı üzerindeki etkisi değerlendirilecektir.

Eksik verileri işlemenin çeşitli yöntemleri vardır. Deterministik modelleme olarak da adlandırılan sayısal modelleme, zaman dizisi verilerinin bilinmeyen bir fonksiyona karşılık geldiğini ve fonksiyonu uygun bir şekilde bulmaya çalıştığını varsayan bir yöntemdir. Bu yöntem, değişkenler arasındaki herhangi bir ilişkiyi bulmaya çalışır ve zaman serisi verileri için *en uygun olanı* temel alır.

Zaman seri modelleme, stokastik modelleme olarak adlandırılan, bilinen veri modellerini tanımlamak için sistematik bir yaklaşım kullanır ve tanımlanan modellerin türünü oluşturabilecek uygun formülü seçer. Bu yöntemde, eksik değer tahmini, bazı sezgisel yöntemleri veya interpolasyon tekniklerini uygulamayı gerektirir. Durum uzay modelleme, gözlemlerin bir gözlem denklemi aracılığıyla sürecin ortalama seviyesi ile ilgili olduğunu varsayar, bir veya daha fazla durum denklemi, bireysel bileşenlerin zaman içinde nasıl değiştiğini ve tahmin denklemlerinin daha sonra yeni tahminleri üretmek için güncellenmesini tanımlar. Bu çalışmada, eksik veriler MATLAB'ın Spline (şekil koruyucu) interpolasyon yöntemi kullanılarak doldurulmuştur. Spline interpolasyon fonksiyonunun seçilme sebebi düzgünlük ölçüsünün diğerlerinden (Doğrusal, Kosinüs, kübik, vb.) daha iyi olmasıdır.

Model için toplanan verilerde, rüzgar hızı ve yağış miktarı verileri için eksik veriler kritik seviyede idi. Bundan dolayı rüzgar ve yağış eksik verileri yapay sinir ağları kullanılarak doldurulmuştur. Diğer hava değişkenleri yardımıyla, Matlab'ın varsayılan NARX yapay sinir ağı, rüzgar ve yağış için eksik verileri tahmin etmek için kullanılmıştır.

Gürültülü Verileri Düzeltme

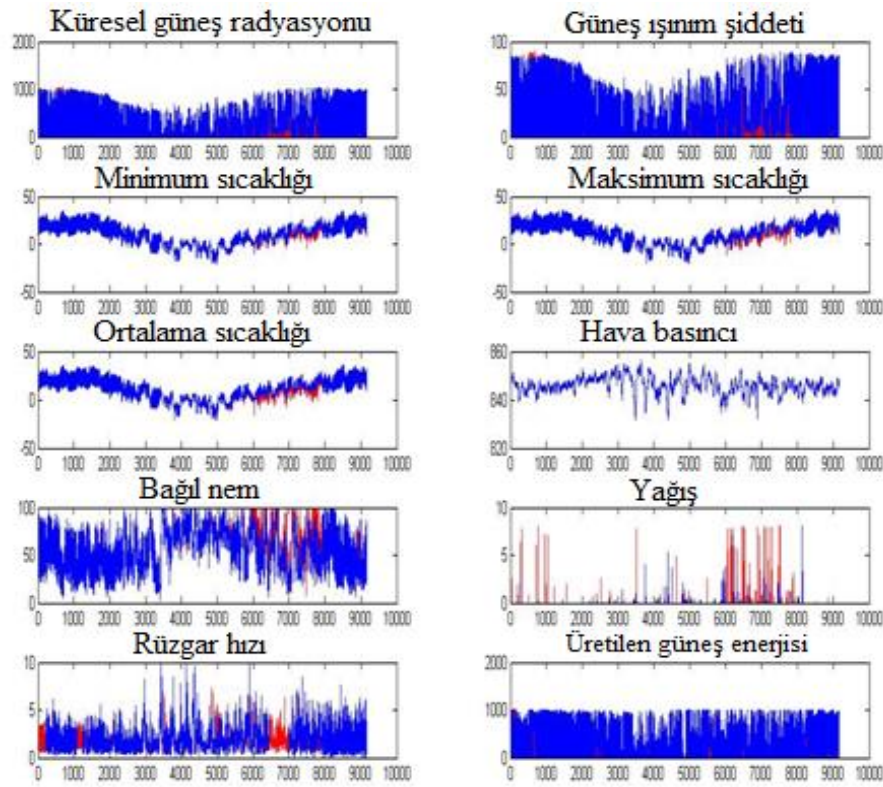
İnterpolasyondan ve eksik verilerin tahmin edilmesinden sonra, sonuçlar incelendi ve bazılarının istenmeyen davranışlar gösterdiği görüldü. Bu sebeple, tolere edilebilir davranışlara sahip olacak şekilde düzeltilmeleri gerekti. Veriler aşağıdaki anlatıldığı gibi değiştirilmiştir:

1. Küresel güneş radyasyonu verileri için, sıfırdan küçük olan tüm değerler sıfıra eşitlenmiştir.
2. Bağıl nem verileri için 100'den büyük değerler 100'e eşitlenmiştir.
3. Güneş ışınım şiddeti verileri için sıfırdan küçük değerler sıfıra eşitlenmiştir.
4. Güneş santrali çıkış gücü verileri için, sıfırdan küçük değerler sıfıra eşitlenmiş ve 1100 kW'tan büyük değerler 1000 kW'a eşitlenmiştir çünkü santral kapasitesi 1000 kW'tır.
5. Yağış miktarı verileri için değerler yuvarlanmıştır.

Şekil 4.2 interpolasyondan sonra tüm verileri gösterir. Mavi renk meteoroloji istasyonundan elde edilen verileri gösterir ve kırmızı renk interpolasyonlu verilerini gösterir.

İstenmeyen Verileri Kaldırma

Güneş enerjisi sadece gündüz kullanılabilir. Bu nedenle, gündeğümü öncesinde ve günbatımından sonra kaydedilen tüm veriler kaldırılmıştır ve 12 Eylül 2016'dan 31 Eylül 2016'ya kadar olan veriler, eksik güneş enerjisi verileri nedeniyle silinmiştir.



Şekil 4. 2: Toplanan Veriler ve Eksik Verilerin Doldurulması

4.2.3. Veri Normalizasyonu

Tüm gerekli veriler elde edildikten sonra, modelin performansını arttırmak için, verilerin aynı aralıkta olması sağlanmıştır. Diğer bir deyişle, modele yapılan tüm girdi verileri 0 ile 1 arasında normalleştirilmiştir. Normalleştirme işlemi aşağıdaki denklem kullanılarak yapılmıştır:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (37)$$

X' normalleştirilmiş değer, X gerçek değeridir ve X_{min} ve X_{max} sırasıyla sütundaki minimum ve maksimum değerlerdir. Modele girdi verileri; saat açısı, zenit açısı, rüzgar hızı, saatlik sıcaklık, minimum sıcaklık, maksimum sıcaklık, yağış miktarı, hava basıncı, bağıl nem, güneş ışınım şiddeti ve küresel güneş radyasyonudur. Hedef verileri güneş santralinin geçmiş çıkış gücüdür. Tablo 5, ön işlemeden sonra bir veri örneğini göstermektedir. Tablo 5'te gösterildiği gibi, üretilen güç verileri normalleştirilmemiştir.

Tablo 5: Ön İşlem Sonrası Veri Örneği

Yıl	Ay	Gün	Saat	Saat Açısı	Zenit Açısı	WDS	MXT	MNT	TMP	PRC	PRS	RLH	SSI	GSR	OUP
2016	6	18	6	0.99396	0.619473	0.13416	0.568055	0.558348	0.553191	0	0.666667	0.826304	0.001429	0.001418	12.251
2016	6	18	7	0.927878	0.504587	0.124285	0.585614	0.556553	0.565603	0	0.691057	0.805869	0.094207	0.094247	64.977
2016	6	18	8	0.861796	0.386463	0.121563	0.622487	0.605027	0.613475	0	0.674797	0.693478	0.281303	0.281324	267.421
2016	6	18	9	0.795714	0.267727	0.133832	0.633022	0.633752	0.62234	0	0.674797	0.652608	0.472137	0.472182	533.116
2016	6	18	10	0.729632	0.152527	0.18364	0.652337	0.633752	0.632979	0	0.691057	0.632173	0.347699	0.347685	689.742
2016	6	18	11	0.66355	0.051595	0.17633	0.687454	0.669659	0.677305	0	0.682927	0.581086	0.516547	0.516611	724.484
2016	6	18	12	0.597468	0.000157	0.217566	0.726084	0.701975	0.712766	0	0.686992	0.529999	0.832148	0.83225	457.09
2016	6	18	13	0.531386	0.04277	0.268154	0.750666	0.718133	0.730496	0	0.678862	0.478912	0.793344	0.793398	827.396
2016	6	18	14	0.465304	0.140813	0.263523	0.773492	0.748654	0.762411	0	0.662602	0.427825	0.926135	0.926214	755.933
2016	6	18	15	0.399222	0.255218	0.326575	0.787539	0.777379	0.776596	0	0.654472	0.417608	0.852484	0.852574	705.567
2016	6	18	16	0.33314	0.373826	0.321425	0.803342	0.789946	0.792553	0	0.642276	0.366521	0.773886	0.773924	556.072
2016	6	18	17	0.267058	0.492149	0.356879	0.80861	0.802513	0.797872	0	0.626016	0.356303	0.598113	0.598191	539.607
2016	6	18	18	0.200976	0.607494	0.352754	0.803342	0.802513	0.796099	0	0.613821	0.356303	0.287789	0.287847	339.081
2016	6	18	19	0.134894	0.717352	0.352643	0.789295	0.797127	0.79078	0	0.613821	0.386956	0.168518	0.168549	97.16
2016	6	18	20	0.068811	0.818705	0.286742	0.780516	0.75763	0.760638	0	0.626016	0.44826	0.049467	0.04944	23.928
2016	6	18	21	0.002729	0.907559	0.216057	0.736619	0.719928	0.723404	0	0.650407	0.509564	0.005716	0.005672	0.646
...															
2017	7	31	6	0.999804	0.66134	0.12	0.538205	0.543986	0.542553	0	0.658537	0.826304	0.002199	0.002458	3.83
2017	7	31	7	0.933722	0.544735	0.12	0.58737	0.545781	0.533688	0	0.654472	0.856956	0.10553	0.105496	41.35
2017	7	31	8	0.86764	0.425956	0.14	0.662872	0.608618	0.595745	0	0.658537	0.744565	0.313292	0.313937	218.32
2017	7	31	9	0.801558	0.308112	0.06	0.690966	0.67684	0.664894	0	0.654472	0.621956	0.501267	0.501392	486.17
2017	7	31	10	0.735475	0.196272	0.14	0.71906	0.707361	0.700355	0	0.646341	0.570869	0.64857	0.648766	694.52
2017	7	31	11	0.669393	0.102038	0.26	0.771736	0.728905	0.721631	0	0.630081	0.519782	0.835446	0.83622	857.14
2017	7	31	12	0.603311	0.053616	0.08	0.815633	0.777379	0.776596	0	0.617886	0.427825	0.921189	0.921771	949.66

2017	7	31	13	0.537229	0.081916	0.3	0.841971	0.825853	0.820922	0	0.601626	0.346086	0.937678	0.937841	962.05
2017	7	31	14	0.471147	0.166996	0.19	0.877089	0.852783	0.849291	0	0.577236	0.305216	0.910196	0.911089	947.43
2017	7	31	15	0.405065	0.275524	0.18	0.906939	0.895871	0.884752	0	0.560976	0.223477	0.82885	0.829887	883.49
2017	7	31	16	0.338983	0.392339	0.2	0.926253	0.915619	0.91844	0	0.54065	0.223477	0.674952	0.675707	753.75
2017	7	31	17	0.272901	0.511211	0.23	0.928009	0.938959	0.923759	0	0.53252	0.17239	0.481481	0.481729	555.29
2017	7	31	18	0.206819	0.628711	0.38	0.913962	0.910233	0.921986	0	0.52439	0.21326	0.253932	0.254383	318.1
2017	7	31	19	0.140737	0.742043	0.28	0.885868	0.883303	0.893617	0	0.528455	0.254129	0.034077	0.034409	91.79
2017	7	31	20	0.074655	0.848082	0.36	0.85953	0.845601	0.865248	0	0.552846	0.325651	0.008794	0.009453	17.29

4.3. Girdi Verileri Seçimi

Zaman serilerinin modellenmesinde girdi değişkenlerinin seçimi çok önemli rol oynar. Bir bağımsız değişkenler grubu mevcut olduğunda, tahmin üzerinde çok az etkisi olan ve bazen de yararlı olanları ihmal etmeyen değişkenlerden kaçınmak için değişken seçimi yapılmalıdır. Girdiler ve hedef değişkenleri arasındaki ilişki doğrusal, kuadratik vb. olabilir. Zaman dizi tahminindeki görevlerden biri, girdi değişkenlerinin seçilmesidir. Değişkenlerin seçimi, veri kullanılabilirliği, kalite ve hedef değişkenle korelasyonuna bağlıdır [9]. Toplanan meteorolojik değişkenler ile güneş enerjisi santralının üretilen gücü arasındaki ilişkiyi tanımlamak için, her bir giriş değişkeninin güneş enerjisi santralinde üretilen güç ile korelasyonunu kontrol etmek için istatistiksel analiz yapılmıştır. Regresyon değeri (R), iki değişken arasındaki doğrusal korelasyonun bir ölçüsüdür, +1 ile -1 arasında bir değeri verir. Burada +1 toplam pozitif korelasyonu, 0 korelasyon olmamasını ve -1 toplam negatif korelasyonu gösterir. Her bir değişken için güneş enerji santralinden üretilen güç ile ilgili R değeri Tablo 6’da gösterilmiştir.

Tablo 6: Güneş Enerji Santralinden Üretilen Güç İle Meteorolojik Değişkenler İçin Regresyon Değerleri


Değişken	Kısaltma	R
Küresel Güneş Radyasyonu	GSR	0.878
Güneş Işınım Şiddeti	SSI	0.878
Saatlik Sıcaklık	TMP	0.270
Minimum Sıcaklık	MNT	0.264
Maksimum Sıcaklık	MXT	0.278
RüzgarHızı	WDS	0.067
Bağıl Nem	RLH	-0.406
Hava Basıncı	PRS	0.2322
YağışMiktarı	PRC	-0.055

Tablo 6’dan, GSR, SSI, TMP, MNT, MXT, RLH ve PRS’nin güneş enerjisi santralinden üretilen gücü ile makul bir korelasyona sahip olduğu, WDS ve PRC’nin ise çok küçük bir korelasyona sahip olduğu görülebilir. Regresyon değerlerine bağlı olarak önemli değişkenleri belirledikten sonra, Tablo 7’de gösterildiği gibi dokuz meteorolojik

değişkenin üç önemli kombinasyonu, güneş santralının enerjisi tahmininde doğruluk üzerindeki etkilerini araştırmak için test edilmiştir. Eksik değerleri doldurulmuş ve eksik değerleri olmayan veriler kullanılarak, her kombinasyon iki kez test edilmiştir. Toplamda, modelde altı farklı veri seti kullanılmıştır. Şekil 4.3, verilerin nasıl toplandığını ve işlendiğini gösteren bir akış şemasıdır.

Tablo 7: Girdi Değişkenlerinin Farklı Kombinasyonlarına Dayalı Girdi Veri Seti

İnterpolasyonlu Veriler		
Veri Seti	1	HA, ZA, MNT, MXT, TMP, PRS, RLH, SSI, GSR, WDS, PRC
	2	HA, ZA, MNT, MXT, TMP, PRS, RLH, SSI, GSR, WDS
	3	HA, ZA, MNT, MXT, TMP, PRS, RLH, SSI, GSR
	İnterpolasyon Olmayan Veriler	
	4	HA, ZA, MNT, MXT, TMP, PRS, RLH, SSI, GSR, WDS, PRC
	5	HA, ZA, MNT, MXT, TMP, PRS, RLH, SSI, GSR, WDS
6	HA, ZA, MNT, MXT, TMP, PRS, RLH, SSI, GSR	



Şekil 4. 3: Veri Toplama ve İşleme Akış Şeması

4.4. Oluşturulan Narx Ağ Modeli

Seri paralel NARX ağı, öğrenme yoluyla geçmiş verileri kullanarak modelin çok adımlı ön tahmin gerçekleştirmesine yardımcı olmak için seçilmiştir. NARX sinir ağı mimarisi üç katmandan, giriş, gizli ve çıktı katmanlarından oluşur. Giriş katmanı farklı girdi bilgisini alır, tek veya birkaç katmandan oluşabilen gizli katman, girdi bilgisini analiz eder ve çıktı katmanı analiz sonuçlarını alır ve çıktıyı sağlar. Giriş katmanında, nöronların sayısı girdiler sayısına eşittir ve çıkış katmanındaki nöronların sayısı çıktı verisi sayısı kadardır, bu model için birdir. Gizli katmandaki nöronların sayısı ve dallı gecikme hattında, giriş gecikmeleri ve geribesleme gecikmelerinin sayısı, ağ performansı ile belirlenir. Bu nedenle, gizli katmandaki nöron sayısının değişmesinin, gecikmelerin sayısının artması ve azaltılmasının üzerindeki etkisini incelenmiştir. Ağ, deneme yanılma yöntemiyle öğrendiği için, en iyi performansı elde etmek için farklı

durumlar dikkate alınmalıdır. Ağ parametreleri, ağ ve model yapısına göre belirlenmelidir. Matlab’da NARX sinir ağı modelini tasarlamak için kullanılan adımlar aşağıdadır.

1. Sinir Ağları (SA) başlangıç grafik kullanıcı arayüzünü (GUI) açılır.
2. SA zaman serisi araçlarını açılır.
3. NARX modelini seçilir.
4. Verileri yüklenil (girdi verileri ve hedef verileri).
5. Verileri içe aktarılır.
6. Verileri, eğitim, doğrulama ve test için bölünür.
7. Gizli nöronların sayısını ve gecikme sayısını seçilir.
8. Ağ eğitim algoritmasını seçilir ve ağı eğitilir (doğrulama hatası düşene kadar eğitim devam edecektir).
9. Ağ performansını doğrulanır (hata otokorelasyonu).
10. Ağın ek doğrulamasını almak için giriş-hatası çapraz-korelasyonunu (input-errorcross-correlation) görüntülenir.
11. Zaman seri yanıtları (responses) (inputs, targets and errors versus time) seçilir.
12. Ağı değerlendirilir.
13. YSA’yı simüle etmek için Matlab fonksiyonunu veya Simulink diyagramını oluşturulur.
14. Kodları oluşturulur ve sonuçları kaydedilir.
15. Komut satırı işlevleri (command-line functions): Bu adımda, GUI’den oluşturulan kodlar, ağ eğitimini özelleştirmek için değiştirilecektir.

Tablo 8, bu çalışmada tasarlanan NARX modelinin parametrelerini göstermektedir.

Tablo 8. Tasarlanan NARX Model Parametreleri


Veri Bölme			
Bölme Fonksiyonu	Eğitim Oranı	Doğrulama Oranı	Test Oranı
Dividrand	%70	%15	%15
Ağ Mimarisi			
Girdi Gecikmesi	Geribildirim Gecikmesi	Gizli Nöronların Sayısını	
4	4	50'dan 150'a Kadar	
Eğitim Algoritması			
trainlm (Levenberg-Marquardt back propagation)			
Performans Fonksiyonu			
MSE ve MAE			
Plot Fonksiyonları			
Performance, train state, error histogram, regression, response, error correlation, input error correlation			
Transfer Fonksiyonu			
Gizli Katman		Çıktı Katmanı	
Hiperbolik Teğeti Sigmoid		Hiperbolik Teğeti Sigmoid	
Ağ Eğitimi			
Açık Döngü Ağı		Kapalı Döngü Ağı	
MAE min hedeften daha az veya eşitse durur		Açık döngü eğitiminden sonra başlar ve MAE, açık döngü ağının MAE'sine eşit veya daha azsa durur	

5. BÖLÜM


SONUÇLAR VE TARTIŞMALAR

5.1. Eğitim Sonuçları

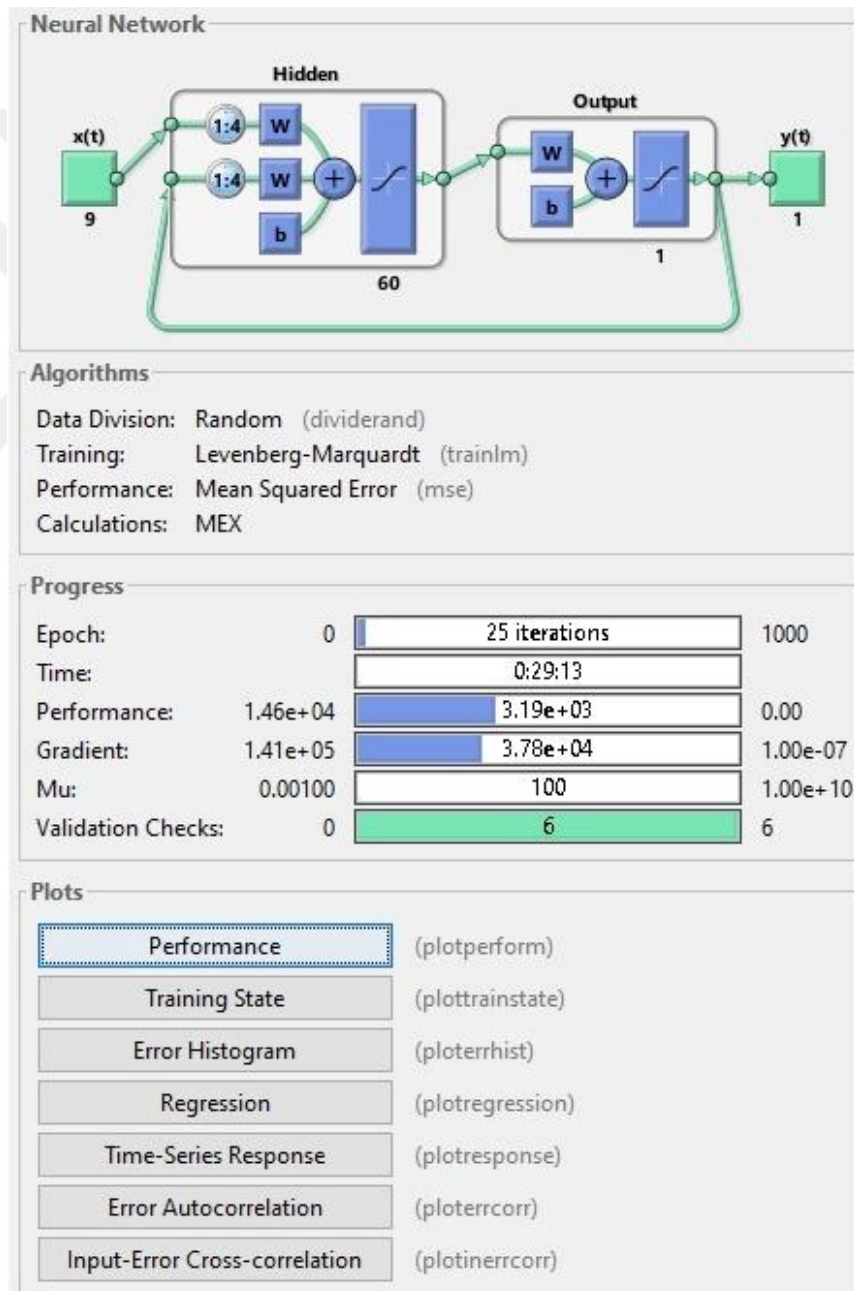
Model iki ardışık adımda eğitilmiştir. NARX ağı, ilk adımda açık döngü modunda, ikinci adımda kapalı döngü modunda eğitilmiştir. Açık döngü ağ eğitimi, modelin mümkün olan en iyi performansa sahip olmasına yardımcı olan gizli nöronların sayısını bulmaya yardımcı olur. Minimum performanslar, 4. Bölüm’de tanımlanan Veri Setlerinden 1, 2 ve 3 için 53 kW ve Veri Setleri 4, 5 ve 6 için 75 kW olarak ayarlanmıştır. Bu değerler, deneme ile mümkün en düşük değerler olarak seçilmiştir. Açık döngü eğitimi, MAE minimum performansından daha az veya eşitse durur. Ayrıca, tüm eğitim, doğrulama ve test adımları dahil olmak üzere açık döngüde yapılır. Kapalı döngü ağ eğitimi, ağın açık döngü modunda performansının iyileştirilmesine yardımcı olur ve çok adımlı ön tahmini gerçekleştirir. Ağ kapalı döngü moduna dönüştürüldüğünde, ağın performansı açık döngü modundaki performansıyla karşılaştırıldığında azalır. Ağın kapalı döngü modunda performansını daha artırmak için ağın yeniden eğitilmesi gerekir. Kapalı döngü modunda eğitim, MAE değeri açık döngü modunun MAE değerinden küçük veya ona eşitse duracak şekilde ayarlanmıştır. Şekil 5.1, 5.2 ve 5.3 açık döngü, kapalı döngü ve kapalı döngüde NARX eğitimini sırasıyla göstermektedir. Şekillerde gösterildiği gibi, Veri Seti 3’te 60 gizli nöron sayısında performans hedefine ulaşılmıştır.



Şekil 5.1. Veri Seti 3 İçin Açık Döngü NARX Ağı



Şekil 5.2. Veri Seti 3 İçin Kapalı Döngü NARX Ağı



Şekil 5.3. Veri Seti 3 İçin Kapalı Döngü Modunda NARX Ağ Eğitimi


Açık döngü ağ eğitiminde, giriş gecikmesi ve geribesleme gecikme sayısı 4 olarak ayarlanmış ve sabit tutulmuştur. Aynı zamanda gizli katmanda, nöronların sayısı değişir, bunların başlangıç sayısı 50'ye ayarlanmıştır. Tablo 9, farklı gizli nöron sayılarında MAE değeri ayarlanan değere ulaşana kadar MAE, MSE ve RMSE değerleri üzerinden ağ performansını göstermektedir. Tabloda gösterildiği gibi 60 gizli nöron sayısında açık döngü ağında MAE 52.598 olmuştur ve elde edilen MAE 53'ten az olduğu için açık döngü eğitimi durdurulmuştur. Daha sonra, ağ kapalı döngü moduna dönüştürülür. Bu durumda MAE, açık döngü ağının MAE'sinden fazla olan 75.121'de kalmıştır. Bu nedenle, NARX ağının aynı sayıda gizli nöronla kapalı döngü modunda yeniden eğitilmesi gerekmiştir. Yeniden eğitimden sonra açık döngüden daha düşük olan 49.550 MAE değeri elde edilmiştir.

Tablo 9: Eğitim Performansı Örneği


AÇIK DÖNGÜ AĞI EĞİTİM SONUÇLARI				
Giriş Gecikmesi Ve Geri Bildirim Gecikmesi	Gizli Nöronları	MAE	MSE	RMSE
4	50	60.226	8158.987	90.327
4	51	59.464	7753.673	88.055
4	52	62.175	8608.265	92.781
4	53	65.412	9600.944	97.984
4	54	66.130	8953.704	94.624
4	55	226.885	99330.621	315.168
4	56	63.432	8531.803	92.368
4	57	58.218	7788.643	88.253
4	58	61.899	8590.365	92.684
4	59	59.505	7573.824	87.028
4	60	52.598	6851.760	82.775
AÇIK DÖNGÜ AĞININ PERFORMANSI				
Giriş Gecikmesi Ve Geri Bildirim Gecikmesi	Gizli Nöronları	MAE	MSE	RMSE
4	60	52.598	6851.760	82.775
KAPALI DÖNGÜ AĞININ PERFORMANSI				
Giriş Gecikmesi Ve Geri Bildirim Gecikmesi	Gizli Nöronları	MAE	MSE	RMSE
4	60	75.121	14342.479	119.760
KAPALI DÖNGÜ AĞI EĞİTİM SONUCU				
Giriş Gecikmesi Ve Geri Bildirim Gecikmesi	Gizli Nöronları	MAE	MSE	RMSE
4	60	54.258	6992.039	83.618
4	60	55.535	7687.068	87.676

4	60	61.104	8891.023	94.292
4	60	60.060	8668.609	93.105
4	60	54.888	7085.870	84.178
4	60	58.973	8293.371	91.068
4	60	59.669	8535.373	92.387
4	60	64.776	10009.502	100.048
4	60	58.439	8109.713	90.054
4	60	58.736	8394.368	91.621
4	60	56.895	7630.564	87.353
4	60	55.195	7116.064	84.357
4	60	53.026	6976.502	83.525
4	60	59.645	8655.497	93.035
4	60	54.286	7102.872	84.279
4	60	57.533	8007.670	89.486
4	60	69.969	11416.287	106.847
4	60	54.612	7244.503	85.115
4	60	58.062	8340.294	91.325
4	60	57.472	7731.970	87.932
4	60	66.741	10815.241	103.996
4	60	64.727	10132.571	100.661
4	60	49.550	5967.414	77.249


Ağın performansı ve davranışları, eğitim sırasında ağ yanıtını gösteren farklı figürlerin yardımıyla görselleştirilebilir. Şekil 5.4, 5.5 ve 5.6, her bir veri seti için sırasıyla doğrulama performansını, regresyonu, eğitim durumunu gösterir. Şekil 5.4, sinir ağının en iyi doğrulama performansını gösterir, ve her bir veri setinde belirlenen hedefe yönelik eğitim sürecinin eğitimini, geçerliliğini, test eğrilerini ve hedefe ulaşılan dönem sayısını gösterir. Şekil 5.5, hedef çıkışları ve tahmin edilen değerlerin arasındaki regresyonu göstermektedir. Şekil 5.5, hedefler ve tahmin edilen değerler arasındaki tahminî doğrusal denklem ve regresyon değerini vermektedir. Hedefe ulaşılan dönemdeki sinir ağının eğitim durumları Şekil 5.6'da gösterilmiştir. Şekil 5.6, sinir ağının gradyan ve ağırlık değişimleri (μ) ve sinir ağ eğitim sürecinin devri (epoch) sırasında doğrulama kontrollerinin sayısına göre nasıl değiştiğini gösterir. Bu eğitim süreci çıktıları, sinir ağının başarılı eğitildiğini göstermektedir. Tablo 10, eğitim performansının bir özetidir.



Şekil 5.4. Doğrulama Performansı



Şekil 5.5. Regresyon Performansı



Şekil 5.6. Eğitim Durumu

Tablo 10: Eğitim Performansı Özeti

		Veri Setleri					
		1	2	3	4	5	6
Gizli Nöronlar		114	52	60	97	79	74
MAE	OL	52.597	51.781	52.596	72.331	72.225	73.669
	CL	47.120	50.091	49.550	67.652	68.619	72.247
MSE	OL	6861.974	6595.902	6851.760	12285.851	11530.717	12177.933
	CL	5537.920	6143.250	5967.414	10714.705	10402.182	11656.805
RMSE	OL	82.837	81.215	82.775	110.842	107.381	110.354
	CL	74.417	78.379	77.249	103.512	101.991	107.967
R		0.97189	0.97241	0.97109	0.94429	0.94768	0.94463
En İyi Doğrulama Performansı		13592.491	13291.327	10177.5125	25558.4469	18685.4462	20784.3782
N'inci Devir		9	11	6	7	11	9
Gradyan		6909.0525	19196.983	14308.7708	16261.5042	6077.2187	36790.3326
mu		10	1	10	10	10	10
Doğrulama Kontrolü		6	6	6	6	6	6
Devir Sayısı		15	17	12	13	17	15

Tablo 10, tüm durumlar için eğitim performansını açık döngü ve kapalı döngü eğitimi için eğitim hatalarını göstermektedir. Kapalı döngü sonuçları ağıın son sonuçlarıdır. Tablo 10'dan görebildiğimiz gibi, genel olarak en iyi performans veri seti 3'ten elde

edilmiştir. Bu veri setinde girdi verilerindeki eksikler doldurulmuş ve rüzgar hızı ile yağış verileri kullanılmamıştır.

5.2. Tahmin Sonuçları


Eğitimden sonra, model, güneş santrali tarafından üretilecek çıkış gücünü 1 Ağustos'tan 8 Ağustos 2017'ye kadar tahmin etmek için kullanıldı. Tahmin edilen sonuçlar saatliktir ve ortalama metodu kullanılarak günlük olarak getirilmiştir. Tablo 11, kW cinsinden saatlik tahminî çıkış gücünü göstermektedir.

Tablo 11: Veri Seti 3 için 01/08/2017 ile 08/08/2017 Tarihleri Arasında Güneş Enerjisi Santralinin Tahminî Gücü


Saat	ÖNGÖRÜLEN ÇIKTI GÜCÜ							
	1.08.2017	2.08.2017	3.08.2017	4.08.2017	5.08.2017	6.08.2017	7.08.2017	8.08.2017
6	6.226952	7.191869	6.744758	45.3979	7.480173	9.477775	5.263201	5.303871
7	49.73485	50.80147	49.92398	7.659137	33.1092	38.08234	43.62207	162.6585
8	210.9208	223.2988	193.3907	91.27872	153.0337	217.9676	167.5513	450.8251
9	462.0838	460.776	421.5026	334.371	362.2243	418.0578	459.6306	693.4595
10	712.2391	711.0683	726.4651	666.3806	649.1333	718.0919	730.6452	903.0636
11	875.9207	875.6845	888.2075	793.8751	838.6441	915.4845	876.0283	980.5693
12	944.775	937.3331	931.9827	876.5985	909.7052	940.9184	948.5048	989.6952
13	941.0625	939.2176	940.1636	864.8639	911.5974	949.6778	975.6544	966.7602
14	906.0853	898.8477	888.8526	797.6548	889.495	951.1779	962.6679	873.1637
15	785.8966	805.8574	763.1911	760.4874	804.0534	880.1307	891.9889	
16	594.5936	623.6061	582.3809	602.9825	653.4402	717.5579	732.5975	
17	407.1552	419.9653	369.8387	427.2538	434.0267	519.2031	534.1141	
18	202.7197	226.4269	187.8609	158.0145	219.3599	281.5422	309.7099	
19	68.02218	77.67913		66.94314	57.16233	81.45213	78.21068	
20	14.18147	15.53742		14.69254	13.57879	12.37292	13.34323	

Şekil 5.7 (a) ve (b)'de sırasıyla veri setleri 1-3 ve 4-6'daki güneş enerjisi santralinden gerçek ve tahmin edilen güçler gösterilmiştir. Grafiklerde, gece boyunca üretimler sıfırdır ve sabah erken saatlerde ve öğleden sonra geç saatlerde sifıra yakındır. Güç üretimi öğlen saatlerinde maksimumdur. Üretimler sabahtan öğlene kadar artar ve öğlen

ve akşam arası azalır. Ayrıca (a) ve (b) şekillerinin karşılaştırılmasından da görüleceği üzere, veri setleri 1-3'teki hatalar veri seti 4-6'dan daha küçüktür. Şekil 5.7 (b) 'deki boş alanlar, veri girişlerden bir veya daha fazlasının eksik olduğu durumlardır.



(a)



(b)

Şekil 5.7. Saatlik Tahmini ve Beklenen Çıkış Gücü

5.3. Tartışmalar ve Gözlemler

Saatlik Gözlemler

Tahmin sonuçları santralden elde edilen gerçek değerler ile karşılaştırılmıştır. Tablo 12, veri seti 3 için saatlik bazda karşılaştırmaları göstermektedir. Tablo 12'de gösterildiği gibi mutlak hata ve mutlak yüzde hatası hesaplanmıştır. Mutlak hata için, minimum ve

maksimum değerler sırasıyla 0.175 kW ve 416.80 kW, genel MAE ise 52.08 kW'dır. Mutlak yüzde hatası için daha yüksek değerler tanımlanmıştır. Daha yüksek değerlerin ortaya çıkması, gerçek çıktı gücünde bazı küçük değerlerin olmasından kaynaklanmaktadır. Genel ortalama mutlak yüzde hatasını hesaplamak için, aykırı değerler (outliers) tespit edilmiş ve kaldırılmıştır. Toplam 17 aykırı değer bulunmuştur. Kalanlar için, minimum ve maksimum mutlak yüzde hata sırasıyla %0.02 ve %56.58'dir ve toplam MAPE %11.83'dür.

Tablo 13, tüm veri setler için saatlik tahmin hatalarını göstermektedir. Gösterildiği gibi, veri seti 3'te MAE, MAPE ve nRMSE için düşük hatalar vardır ve veri seti 2'de de MBE için düşük hata gözlenmektedir.

Günlük Gözlemler

Saatlik tahmin edilen verileri, santralin üretim saatlerinde her gün için ortalama güç hesaplanarak günlük olarak dönüştürülmüştür. Tablo 14'te, veri seti 3 için günlük tahmin ve günlük gerçek veriler için bir örnek gösterilmektedir. Tabloda gösterildiği gibi, genel MAE ve MAPE sırasıyla 20.858 ve %4.60'tır.

Tablo 15, tüm veri setleri için günlük hataları göstermektedir. Gösterildiği gibi, veri seti 2, günlük tahminde, MAE, MAPE, MBE ve nRMSE için daha düşük hata vermektedir.

Elde edilen modelden aşağıdaki sonuçlar çıkarılmaktadır.

1. İnterpolasyonlu girdi veri seti daha iyi tahmin sonuçları üretmektedir.
2. İnterpolasyon ve eksik verilerin doldurulması ağın performansına katkıda bulunur.
3. Güneş santralının enerji üretimi saatlik olarak %11.83 MAPE ve %8.57 nRMSE ve günlük olarak %3.59 MAPE ve %3.59 nRMSE ile tahmin edilebilir.
4. Hava tahminlerinin daha iyi yapılması ile tüm hatalarda azalma sağlanacaktır.
5. Hava tahminlerinin güç santraline yakın yapılması da hataları azaltacaktır.

Tablo 12 Saatlik Gerçek Gücü Ve Tahmin Gücü

Yıl	Ay	Gün	Saat	ROUP	FOUP	ERR	ERR2	ABE	APE	Aykırı
2017	8	1	6	3.45	6.227	2.777	7.711	2.777	%80.49	1
2017	8	1	7	37.96	49.735	11.775	138.647	11.775	%31.02	0
2017	8	1	8	203.48	210.921	7.441	55.366	7.441	%3.66	0
2017	8	1	9	458.95	462.084	3.134	9.821	3.134	%0.68	0
2017	8	1	10	666.12	712.239	46.119	2126.974	46.119	%6.92	0
2017	8	1	11	824.78	875.921	51.141	2615.373	51.141	%6.20	0
2017	8	1	12	876.55	944.775	68.225	4654.652	68.225	%7.78	0
2017	8	1	13	887.69	941.062	53.372	2848.625	53.372	%6.01	0
2017	8	1	14	906.26	906.085	-0.175	0.03	0.175	%0.02	0
2017	8	1	15	745.57	785.897	40.327	1626.235	40.327	%5.41	0
2017	8	1	16	693.18	594.594	-98.586	9719.271	98.586	%14.22	0
2017	8	1	17	525.43	407.155	-118.275	13988.93	118.275	%22.51	0
2017	8	1	18	304.59	202.72	-101.87	10377.56	101.87	%33.45	0
2017	8	1	19	111.54	68.022	-43.518	1893.8	43.518	%39.02	0
2017	8	1	20	19.915	14.181	-5.734	32.874	5.734	%28.79	0
2017	8	2	6	2.01	7.192	5.182	26.852	5.182	%257.80	1
2017	8	2	7	37.95	50.801	12.851	165.16	12.851	%33.86	0
2017	8	2	8	206.2	223.299	17.099	292.369	17.099	%8.29	0
2017	8	2	9	451.7	460.776	9.074	82.373	9.074	%2.01	0
2017	8	2	10	657.02	711.068	54.048	2921.22	54.048	%8.23	0
2017	8	2	11	810.42	875.684	65.264	4259.461	65.264	%8.05	0
2017	8	2	12	874.1	937.333	63.233	3998.429	63.233	%7.23	0
2017	8	2	13	883.05	939.218	56.168	3154.803	56.168	%6.36	0
2017	8	2	14	869.27	898.848	29.577	874.841	29.577	%3.40	0
2017	8	2	15	823.78	805.857	-17.923	321.221	17.923	%2.18	0
2017	8	2	16	717.49	623.606	-93.884	8814.186	93.884	%13.09	0
2017	8	2	17	532.99	419.965	-113.025	12774.59	113.025	%21.21	0
2017	8	2	18	299.26	226.427	-72.833	5304.667	72.833	%24.34	0
2017	8	2	19	99.41	77.679	-21.731	472.231	21.731	%21.86	0
2017	8	2	20	13.143	15.537	2.395	5.734	2.395	%18.22	0
2017	8	3	6	3.46	6.745	3.285	10.79	3.285	%94.94	1
2017	8	3	7	41.3	49.924	8.624	74.373	8.624	%20.88	0
2017	8	3	8	205.72	193.391	-12.329	152.012	12.329	%5.99	0
2017	8	3	9	450.29	421.503	-28.787	828.714	28.787	%6.39	0
2017	8	3	10	654.02	726.465	72.445	5248.288	72.445	%11.08	0
2017	8	3	11	815.53	888.207	72.677	5282.02	72.677	%8.91	0
2017	8	3	12	917.94	931.983	14.043	197.198	14.043	%1.53	0
2017	8	3	13	946.73	940.164	-6.566	43.117	6.566	%0.69	0
2017	8	3	14	861.33	888.853	27.522	757.492	27.522	%3.20	0
2017	8	3	15	662.53	763.191	100.661	10132.65	100.661	%15.19	0
2017	8	3	16	467.52	582.381	114.861	13193.02	114.861	%24.57	0

2017	8	3	17	222.09	369.839	147.749	21829.69	147.749	%66.53	1
2017	8	3	18	61.469	187.861	126.392	15975	126.392	%205.62	1
2017	8	4	6	3.23	45.398	42.168	1778.132	42.168	%1305.51	1
2017	8	4	7	45.8	7.64	-38.141	1454.725	38.141	%83.28	1
2017	8	4	8	210.21	91.279	-118.931	14144.65	118.931	%56.58	0
2017	8	4	9	446.83	334.371	-112.459	12647.02	112.459	%25.17	0
2017	8	4	10	673.22	666.381	-6.839	46.777	6.839	%1.02	0
2017	8	4	11	848.76	793.875	-54.885	3012.347	54.885	%6.47	0
2017	8	4	12	848.68	876.599	27.918	779.443	27.918	%3.29	0
2017	8	4	13	804.73	864.864	60.134	3616.091	60.134	%7.47	0
2017	8	4	14	940.99	797.655	-143.335	20544.98	143.335	%15.23	0
2017	8	4	15	602.58	760.487	157.907	24934.74	157.907	%26.21	0
2017	8	4	16	186.18	602.982	416.802	173724.4	416.802	%223.87	1
2017	8	4	17	13.43	427.254	413.824	171250.3	413.824	%3081.38	1
2017	8	4	18	2.82	158.014	155.194	24085.32	155.194	%5503.35	1
2017	8	4	19	15.06	66.943	51.883	2691.86	51.883	%344.51	1
2017	8	4	20	5.79	14.692	8.902	79.255	8.902	%153.76	1
2017	8	5	6	3.62	7.48	3.86	14.901	3.86	%106.63	1
2017	8	5	7	40.74	33.109	-7.631	58.229	7.631	%18.73	0
2017	8	5	8	216.23	153.033	-63.196	3993.774	63.196	%29.23	0
2017	8	5	9	433.72	362.224	-71.496	5111.636	71.496	%16.48	0
2017	8	5	10	503.84	649.133	145.293	21110.14	145.293	%28.84	0
2017	8	5	11	849.15	838.644	-10.506	110.374	10.506	%1.24	0
2017	8	5	12	922.29	909.705	-12.585	158.376	12.585	%1.36	0
2017	8	5	13	938.1	911.597	-26.503	702.387	26.503	%2.83	0
2017	8	5	14	927.76	889.495	-38.265	1464.21	38.265	%4.12	0
2017	8	5	15	880.45	804.053	-76.397	5836.447	76.397	%8.68	0
2017	8	5	16	769.52	653.44	-116.08	13474.53	116.08	%15.08	0
2017	8	5	17	568.09	434.027	-134.063	17972.97	134.063	%23.60	0
2017	8	5	18	337.99	219.36	-118.63	14073.1	118.63	%35.10	0
2017	8	5	19	27.77	57.162	29.392	863.909	29.392	%105.84	1
2017	8	5	20	9.37	13.579	4.209	17.714	4.209	%44.92	0
2017	8	6	6	3.43	9.478	6.048	36.576	6.048	%176.32	1
2017	8	6	7	37.02	38.082	1.062	1.129	1.062	%2.87	0
2017	8	6	8	224.4	217.968	-6.432	41.375	6.432	%2.87	0
2017	8	6	9	498.04	418.058	-79.982	6397.149	79.982	%16.06	0
2017	8	6	10	719.3	718.092	-1.208	1.46	1.208	%0.17	0
2017	8	6	11	742.61	915.484	172.874	29885.6	172.874	%23.28	0
2017	8	6	12	920.9	940.918	20.018	400.734	20.018	%2.17	0
2017	8	6	13	954.6	949.678	-4.922	24.228	4.922	%0.52	0
2017	8	6	14	904.48	951.178	46.698	2180.698	46.698	%5.16	0
2017	8	6	15	875.7	880.131	4.431	19.631	4.431	%0.51	0
2017	8	6	16	773.17	717.558	-55.612	3092.702	55.612	%7.19	0
2017	8	6	17	581.36	519.203	-62.157	3863.478	62.157	%10.69	0

2017	8	6	18	329.04	281.542	-47.498	2256.037	47.498	%14.44	0
2017	8	6	19	88.45	81.452	-6.998	48.97	6.998	%7.91	0
2017	8	6	20	13.79	12.373	-1.417	2.008	1.417	%10.28	0
2017	8	7	6	2.82	5.263	2.443	5.969	2.443	%86.64	1
2017	8	7	7	34.82	43.622	8.802	77.476	8.802	%25.28	0
2017	8	7	8	203.07	167.551	-35.519	1261.578	35.519	%17.49	0
2017	8	7	9	461.93	459.631	-2.299	5.287	2.299	%0.50	0
2017	8	7	10	707.63	730.645	23.015	529.7	23.015	%3.25	0
2017	8	7	11	848.09	876.028	27.938	780.548	27.938	%3.29	0
2017	8	7	12	928.29	948.505	20.215	408.638	20.215	%2.18	0
2017	8	7	13	969.58	975.654	6.074	36.899	6.074	%0.63	0
2017	8	7	14	975.12	962.668	-12.452	155.056	12.452	%1.28	0
2017	8	7	15	916.24	891.989	-24.251	588.116	24.251	%2.65	0
2017	8	7	16	778.78	732.598	-46.182	2132.822	46.182	%5.93	0
2017	8	7	17	580.03	534.114	-45.916	2108.269	45.916	%7.92	0
2017	8	7	18	324.41	309.71	-14.7	216.093	14.7	%4.53	0
2017	8	7	19	84.2	78.211	-5.989	35.872	5.989	%7.11	0
2017	8	7	20	17.6	13.343	-4.257	18.12	4.257	%24.19	0
2017	8	8	7	0.89	5.304	4.414	19.482	4.414	%495.94	1
2017	8	8	8	209.63	162.658	-46.971	2206.322	46.971	%22.41	0
2017	8	8	9	496.43	450.825	-45.605	2079.808	45.605	%9.19	0
2017	8	8	10	708.42	693.459	-14.96	223.817	14.96	%2.11	0
2017	8	8	11	837.74	903.064	65.324	4267.177	65.324	%7.80	0
2017	8	8	12	911.16	980.569	69.409	4817.652	69.409	%7.62	0
2017	8	8	13	933.66	989.695	56.035	3139.943	56.035	%6.00	0
2017	8	8	14	927.75	966.76	39.01	1521.797	39.01	%4.20	0
2017	8	8	15	877.02	873.164	-3.856	14.871	3.856	%0.44	0
Mape İçin Aykırı Değer Tespiti					Q1	Q3	IQR	Üst sınır	Alt sınır	Aykırı Sayısı
					0.036	0.255	0.219	0.584	-0.293	17
Hata					MROUP	MFOUP	MAE	MAPE	MBE	nRMSE
					494.033	502.287	52.081	%11.83	8.254	%8.57

Tablo 13. Tüm Veri Setler İçin Saatlik Tahmin Hatası

Veri Seti	MAE	MAPE	MBE	nRMSE
1	66.489	%17.93	-1.468	%10.27
2	68.445	%15.39	-0.0242	%10.49
3	52.0815	%11.83	8.253	%8.57
4	113.001	%29.67	-8.0138	%18.43
5	153.835	%39.13	4.434	%24.99
6	86.0227	%20.53	-19.354	%12.83

Tablo 14. Veri Seti 3 İçin Günlük Gerçek Güç ve Öngörülen Güç

Yıl	Ay	Gün	Saat	ROUP	FOUP	ERR	ERR2	ABE	PE
2017	8	1	15	484.364	478.7745	-5.58981	31.24602	5.589814	%1.15
2017	8	2	15	485.186	484.8861	-0.30008	0.090048	0.30008	%0.06
2017	8	3	13	485.379	534.6542	49.27511	2428.037	49.27511	%10.15
2017	8	4	15	376.554	433.8969	57.34293	3288.211	57.34293	%15.23
2017	8	5	15	495.242	462.4029	-32.8398	1078.45	32.83976	%6.63
2017	8	6	15	511.086	510.0797	-1.00633	1.012693	1.006327	%0.20
2017	8	7	15	522.174	515.3021	-6.87186	47.22251	6.871863	%1.32
2017	8	8	9	655.8556	669.4999	13.64434	186.1679	13.64434	%2.08
				MROUP	MFOUP	MBE	nRMSE	MAE	MAPE
				501.9802	511.187	9.206817	%4.53	20.85878	%4.60

Tablo 15. Tüm Veri Setler İçin Günlük Tahmin Hatası

Durum	MAE	MAPE	MBE	nRMSE
1	44.492	%9.05	-4.181	%8.44
2	17.396	%3.59	1.0163	%3.59
3	20.858	%4.60	9.206	%4.53
4	80.078	%14.47	-16.818	%15.98
5	106.077	%20.08	-12.621	%25.73
6	34.748	%6.69	-18.929	%6.63

KAYNAKÇA

1. Das, U.K., Tey, K.S, Seyedmahmoudian, M., Mekhilef, S., Idris, M.Y.I., Deventerc, W.V., Horan, B., Stojcevski, A., 2018, Forecasting of photovoltaic power generation and model optimization: a review. **Renewable and Sustainable Energy Reviews, Cilt (81):** 912-928.
2. Cadenas. E., Rivera, W., Amezcua, C.R., Heard, C., 2016, wind speed prediction using a univariate ARIMA model and a multivariate NARX model. **Energies, Cilt (9):** 1-15.
3. Cai, T., Duan, S., Chen, C., 2010, forecasting power output for grid-connected photovoltaic power system without using solar radiation measurement. International Symposium on Power **Electronics for Distributed Generation Systems, Cilt (2):** 773-777.
4. Ahmad, A., Anderson, T., 2014, global solar radiation prediction using artificial neural network models for New Zealand. **Australian Solar Energy Society (Australian Solar Council), Cilt (52):** 141-150.
5. Ahmad, A., Anderson, T.N., Lie, T.T., 2015, hourly global solar irradiation forecasting for New Zealand. **Solar Energy, Cilt (122):** 1398-1408.
6. Mohammed, B., Hamdana, A., Abdelhafeza, A., Shaheenb, W., 2013, hourly solar radiation prediction based on nonlinear autoregressive exogenous (NARX) neural network. **Jordan Journal of Mechanical and Industrial Engineering, Cilt (7):** 11-18.
7. Sharma, G., Pandey, A., Chaudhary, P., 2016, prediction of output solar power generation using neural network time series method. International Conference on Electrical, Electronics, Engineering Trends, Communication, **Optimization and Sciences (EEECOS), Cilt (3):** 806-808.
8. DiPiazza, A., DiPiazza, M., Vitale, G., 2016, solar and wind forecasting by NARX neural networks. **Renewable Energy and Environmental Sustainability, Cilt (39):** 1-5.
9. Al Shamisi, M. H., Al S., Ali, H., Hassan, A., 2011. Using MATLAB to Develop Artificial Neural Network Models for Predicting Global Solar Radiation in Al Ain City – UAE, 219 – 238” *In: Engineering Education and Research Using MATLAB* (Eds: A., Ali). IntechOpen, Shanghai.

10. Sandhya, T., Kavitha, V.R., 2015, estimation of solar radiation with various climatic parameters based on neural network. **International Journal of Emerging Technology in Computer Science & Electronics (IJETCSE)**, Cilt (13): 151-155.
11. Saima, H., Jaafar, J., Belhaouari, S., Jillani, T.A., 2011, intelligent methods for weather forecasting: a review. (Web sayfası: <https://www.researchgate.net>), (Erişim tarihi: Eylül 2011).
12. Kardakos, E.G., Alexiadis, M.C., Vagropoulos, S.I., Simoglou, C.K., Biskas, P.N., Bakirtzis, A.G., 2013, application of time series and artificial neural network models in short-term forecasting of PV power generation. 48th International Universities' Power Engineering Conference (UPEC).
13. Tsoutsos, D.T., Frantzeskaki, N., Gekas, V., 2005, environmental impacts from the solar energy technologies. **Energy Policy**, Cilt (33): 289-296.
14. Frohlich, C., Brusa, R.W., 1981, solar radiation and its variation in time. **Solar physics**, Cilt(74): 209-215.
15. Tiwari, G.N., Dubey, S., 2010. Fundamentals of photovoltaic modules and their applications. Centre for Energy Studies, Indian Institute of Technology (IIT) Delhi, New Delhi, India, 423 s/pp.
16. Solangi, K.H., Islam, M.R., Saidur, R., Rahim, N.A., Fayaz, H., 2011, a review on global solar energy policy. **Renewable and sustainable energy reviews**, Cilt (15): 2149-2163.
17. Mandil, C., 2004. World international outlook 2004. (Web sayfası: <https://www.oecd-ilibrary.org>), (Erişim tarihi: Ekim 2004).
18. Maehlum, A.M., 2013. Potential of solar energy. (Web sayfası: <http://www.energyinformative.org>), (Erişim tarihi: Haziran 2013).
19. Ian, 2016. World solar PV energy potential maps. (Web sayfası: <https://britishbusinessenergy.co.uk/world-solar-map/>), (Erişim tarihi: Kasım 2016).
20. Şaylan, L., Şen, O., Toros, H., Arısoy, A., 2002, solar energy potential for heating and cooling systems in big cities of turkey. **Energy conversion and management**, Cilt (43): 1829-1837.

21. Baris, K., Kucukali, S., 2012, availability of renewable energy sources in Turkey: current situation, potential, government policies and the EU perspective. **Energy policy, Cilt (42): 377-391.**
22. Cetinkaya, S., 2013. Turkey: Solar Power Market in Turkey. (**Web sayfası: <http://www.iberglobal.com>**), (Erişim tarihi: Eylül 2013).
23. Duman, F., 2014. Güneş Pili-Termal Hibrit Sistemin (PV-T) Optimizasyonunun Deneysel Olarak İncelenmesi. Erciyes Üniversitesi, Yüksek Lisans Tezi, Kayseri, 56 s.
24. Gürbüz, K., 2013. Birleşik Parabolik Yoğunlaştırıcı Güneş Kolektörleri İle Buhar Üretiminin Deneysel ve Teorik İncelenmesi. Erciyes Üniversitesi, Yüksek Lisans Tezi, Kayseri, 72 s.
25. Chu, Y., Meisen, P., 2011. Review and Comparison of Different Solar Energy Technologies. (**Web sayfası: <http://www.geni.org>**), (Erişim tarihi: Ağustos 2011).
26. Mark V. Fedkin Mark V., 2018. Utility Solar Power and Concentration. (**Web sayfası: <https://www.e-education.psu.edu/eme812>**), (Erişim tarihi: Ocak 2018).
27. Aghaei T.P., Meisen, P., 2014. Solar Electric and Solar Thermal Energy: A Summary of Current Technologies. (**Web sayfası: <http://www.geni.org>**), (Erişim tarihi: November 2014).
28. Zhang, H.L., Baeyens, J., Degreè, J., Cacères, G., 2013, concentrated solar powerplants: review and design methodology. **Renewable and sustainable energy reviews, Cilt (22): 466-481**
29. REJA Amatya, R., Bushett, F., Campanella, A., Kavlak, G., Macko, J., Maurano, A., McNerney, J., Osedach, T., Rodilla, P., Rose, A., Sakti, A., Steinfeld, E., Trancik, J., Tuller, H., 2015. The Future of Solar Energy. Massachusetts Institute of Technology, Boston, 356 s/pp.
30. Lorenz, E., Hurka, J., Heinemann, D., Beyer, G.H., 2009, irradiance forecasting for the power prediction of grid-connected photovoltaic systems. **IEEE journal of selected topics in applied earth observations and remote sensing, Cilt (2): 1-9.**

31. Strmčnik, B., Dodig, V., Žertek, A., Skubic, A., Lager, B., MatjažTitovšek, M., 2014. Report on the Overview of Forecasting Techniques for Production and Consumption. Eindhoven University of Technology, Eindhoven, 61 s/pp.
32. Huang, R., Huang, T., Gadh, R., 2012, solar generation prediction using the ARMA model in a laboratory-level micro-grid. **International conference on smart grid communications, Cilt (3):** 528-533.
33. Diagne, M., David, M., Lauret, P., Boland, J., Schmutz, N., 2013, review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews, Cilt (27):** 65-76.
34. Wan, C., Zhao, J., Song, Y., Xu, Z., Lin, J., Hu, Z., 2015, photovoltaic and solar power forecasting for smart grid energy management. **CSEE journal of power and energy systems, Cilt (1):** 38-46.
35. Hong, W.C., 2013. intelligent energy demand forecasting, 21-40''In: Intelligent Energy Demand Forecasting (W. C. Hong). Oriental Institute of Technology, New Taipei City Taiwan.
36. Basheer, I.A., Hajmeer, M., 2000, artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods, Cilt (43):** 3-31.
37. daSilva, I.N., Spatti, D.H., Flauzino, R.A., Liboni, L.H.B., Alves, S.F.R., 2017. artificial neural network architectures and training processes, 21-28''In: Artificial Neural Networks (Eds: I.N. da Silva, D.H. Spatti, R. A. Flauzino, L.H.B. Liboni, S.F.R. Alves). Springer International Publishing Switzerland.
38. Rakshit, S., Dwarakish, G.S., Natesan, U., 2014, tidal-level forecasting using artificial neural networks along the west-coast of India. **Journal of JSCE, Cilt (2):** 176-187.
39. Vaz, A.G.R., Elsinga, B., van Sark, W.G.J.H.M., Brito, M.C., 2016, an artificial neural network to assess the impact of neighbouring photovoltaic systems in power forecasting in Utrecht. **Renewable Energy, Cilt (85):** 631-641.
40. Palit, A.K., Popovic, D., 2005. Computational Intelligence in Time Series Forecasting. British Library, London, Kasım 2005.
41. Xie, T., Yu, H., Hewlett, J., Rózycki, P., Wilamowski, B., 2012, fast and efficient second-order method for training radial basis function networks. **IEEE transactions on neural networks and learning systems, Cilt(23):** 609-619.

42. Wilamowski, B.M., Yu, H., 2010, improved computation for levenberg–marquardt training. **IEEE transactions on neural networks, Cilt (21)**: 930-937.
43. Chen, R.J., Bloomfield, P., Fu, J.S., 2003, an evaluation of alternative forecasting methods to recreation visitation. **Journal of Leisure Research, Cilt (35)**: 441-454.



EKLER

EK 1. MATLAB CODE FOR NARX MODEL

```

%% MATLAB CODE FOR NARX MODEL;
%% Load excel data in matlab;
datatouse=data;
%% DATA FOR TRAINING
input=datatouse(:,1:6); % Exogenous inputs
target=datatouse(:,7); % Target
E=tonndata(input,false,false);
P=tonndata(target,false,false);
X= E; % Exogenous input data into NARX MODEL FOR TRAINING
T= P; % Tagert data into NARX MODEL FOR TRAINING
%% DATA FOR PREDICTION AND NARX MODEL PERFORMANCE EVALUATION
input_predict=data2(:,1:6); % Exogenous input for prediction
E1=tonndata(input_predict,false,false);
X1= E1;
%% NETWORK ARCHITECTURE
delay=4;
min_err = inf;
desired_err =53;
fprintf('%18s\n','OPEN LOOP NETWORK TRAINING RESULT');
fprintf('%12s %24s %24s\r\n','MAE','MSE','RMSE');
while min_err>desired_err
for neuronsHiddenLayer=50:1:150 % Number of Neurons in the Hidden Layer
% Network Creation
net = narxnet(1:delay,1:delay,neuronsHiddenLayer);
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};
%% TRAINING THE NETWORK
[x,xi,ai,t] = preparets(net,X,{},T); %Customize training
parameters
net.trainFcn = 'trainlm'; % Levenberg-Marquardt algoritihm
net.trainParam.epochs = 1000;
net.divideFcn = 'dividerand';
net.divideMode = 'time';
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;

```

```

net.divideParam.testRatio = 15/100;
% Choose Performance Function:
net.performFcn = 'mse'; % Mean squared error
% Activation functions
net.plotFcns = {'plotperform','plottrainstate', 'ploterrhist', ...
    'plotregression', 'plotresponse', 'ploterrcorr', 'plotinerrcorr'};
net.layers{1}.transferFcn = 'tansig';
net.layers{2}.transferFcn = 'tansig';
% Train the Network
    [net,tr] = train(net,x,t,xi,ai);
y = net(x,xi,ai);
openloopperformance = perform(net,t,y);
trainTargets = gmultiply(t,tr.trainMask);
valTargets = gmultiply(t,tr.valMask);
testTargets = gmultiply(t,tr.testMask);
trainPerformance = perform(net,trainTargets,y);
valPerformance = perform(net,valTargets,y);
testPerformance = perform(net,testTargets,y);
MAEt = mae(net,t,y); % mean absolute error
MSEt = mse(net,t,y); % mean square error
RMSEt = sqrt(MSEt); % root mean square error
fprintf('%12.3f %24.3f %24.3f\r\n',MAEt, MSEt, RMSEt);
if MAEt<min_err
min_err= MAEt;
if min_err<= desired_err
break;
end
end
end
end
neto=net;
view(neto)
figure, plotperform(tr)
figure, plottrainstate(tr)
figure, plotregression(t,y)
figure, plotresponse(t,y)
% Results openloop network
errors = gsubtract(t,y); % Network prediction errors
MAEo=mae(neto,t,y); % mean absolute error
MSEo = mse(neto,t,y); % means square error

```

```

RMSEo = sqrt(MSEo);          % root mean square error
fprintf('%18s\n','OPEN LOOP NETWORK PERFORMANCE');
fprintf('%12s %24s %24s\r\n','MAE','MSE','RMSE');
fprintf('%12.3f %24.3f %24.3f\r\n',MAEo, MSEo, RMSEo);

% Results: closed loop network

netc = closeloop(neto);
netc.name = [net.name ' -ClosedLoop'];
[xc,xic,aic,tc] = preparets(netc,X,{},T);
yc = netc(xc,xic,aic);
closedLoopPerformancel = perform(netc,tc,yc);

MAEc=mae(netc,tc,yc);        % mean absolute error
MSEc = mse(netc,tc,yc);      % mean square error
RMSEc = sqrt(MSEc);          % root mean square error

fprintf('%18s\n','CLOSED LOOP NETWORK PERFORMANCE');
fprintf('%12s %24s %24s\r\n','MAE','MSE','RMSE');
fprintf('%12.3f %24.3f %24.3f\r\n',MAEc, MSEc, RMSEc);

%% MULTI-STEP AHEAD PREDICTION

fprintf('%18s\n','CLOSED LOOP NETWORK TRAINING RESULT');
fprintf('%12s %24s %24s\r\n','MAE','MSE','RMSE');

closeddesired_err=MAEt;
[x1,xio,aio] = preparets(neto,X,{},T);
[y1,xfo,afo] = neto(x1,xio,aio);
x2 = X1;
[netc,xic,aic] = closeloop(neto,xfo,afo);
while MAEc>closeddesired_err
    [net,tr] = train(netc,xc,tc,xic,aic);
yc= net(xc,xic,aic);
MAEct = mae(net,tc,yc);
MSEct = mse(net,tc,yc);
RMSEct = sqrt(MSEct) ;
fprintf('%12.3f %24.3f %24.3f\r\n',MAEct, MSEct, RMSEct);
if MAEct<MAEc

```

```
MAEc= MAEct;
if MAEc<= closeddesired_err
break;
end
end
end
closedLoopPerformance2 = perform(net,tc,yc);
net=netc;
y2= netc(x2,xic,aic);
y2;

%% FIGURE
figure;
plot([cell2mat(tc); cell2mat(yc)]')
legend('OriginalTargets','Network Predictions')
figure;
plot(cell2mat(y2)')
legend('outputPredictions')
% Predictions in excel file
Y2=cell2mat(y2);
Y2=Y2';
output_pr=[data2(:,1:4) Y2];
filename='predictionresult.xlsx';
xlswrite(filename,output_pr);
```

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Obed NKURIYINGOMA
Uyruğu: Ruanda
Doğum Tarihi ve Yeri: 19.06.1987 -Ruanda
Medeni Durum: Bekar
e-mail: nkuliyobas@yahoo.fr
Yazışma Adresi: Huye-Ruanda

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Enerji Sistemleri Mühendislik	2018
Lisans	KigaliInstitute of Science and Technology, Elektrik Mühendislik	2012
Lise	College Adventist de Gitwe, Ruhango	2006

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2012-2103	Ruanda Standart Kurulu	Bakım ve kurulum görevlisi
2011-2012	GahogoAdventist Akademisi	Matematik öğretmenlik

YABANCI DİL

İngilizce, Fransızca