



**GÜNEŞ IŞINIM TAHMİNİ İÇİN FARKLI GÜNEŞLENME
DURUMLARINI DİKKATE ALAN HİBRİT BİR YÖNTEM TASARIMI**

YÜKSEK LİSANS TEZİ

Fatimetou H'MEİNDE MAHAM

Danışman

Dr. Öğr. Üyesi Emre AKARSLAN

**ELEKTRİK MÜHENDİSLİĞİ – YENİLENEBİLİR ENERJİ SİSTEMLERİ
ANABİLİM DALI**

Ocak 2022

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**GÜNEŞ IŞINIM TAHMİNİ İÇİN FARKLI GÜNEŞLENME
DURUMLARINI DİKKATE ALAN HİBRİT BİR YÖNTEM
TASARIMI**

Fatimetou H'MEİNDE MAHAM

Danışman

Dr. Öğr. Üyesi Emre AKARSLAN

**ELEKTRİK MÜHENDİSLİĞİ – YENİLENEBİLİR ENERJİ
SİSTEMLERİ
ANABİLİM DALI**

Ocak 2022

ÖZET

Yüksek Lisans Tezi

GÜNEŞ IŞINIM TAHMİNİ İÇİN FARKLI GÜNEŞLENME DURUMLARINI DİKKATE ALAN HİBRİT BİR YÖNTEM TASARIMI

Fatimetou H'MEİNDE MAHAM

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Yenilenebilir Enerji Sistemleri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Emre AKARSLAN

Dünyada sürekli artan nüfus ve gelişen teknoloji, enerji ihtiyacının sürekli olarak artmasına neden olmaktadır. Hem çevresel hassasiyetler hem de artan enerji ihtiyacını karşılamak için, temiz enerji kaynaklarının kullanımı bir zorunluluk haline gelmiştir. Güneş enerjisi bu kaynakların en önemlilerinden bir tanesi olmakla beraber, ışıınının değişken ve kesikli yapısı nedeniyle üretilecek olan enerji de değişken olmaktadır. Bu sebeple güneşten üretilecek olan enerjinin belirlenmesi ve bir üretim planlaması yapılabilmesi için öncelikle güneş ışıınının değeri doğru bir şekilde belirlenmesi gerekir. Bu çalışmada, güneş ışıınının tahmini için bulutluluk indeksine bağlı olarak tahmin modelinin seçildiği hibrit bir yöntem önerilmiştir. Çalışmada, Türkiye Meteoroloji Genel Müdürlüğünden (TMGM) elde edilen Mardin iline ait iki yıllık (2013-2014) güneş ışıınının verisi kullanılmıştır. Veriler eğitim ve test olmak üzere iki bölüme ayrılmış olup, eğitim için 2013 yılı ve test için 2014 yılı güneş ışıınının verileri kullanılmıştır. Tahmin edici olarak Yapay sinir ağları, NARX ağı ve Ridge regresyon yöntemleri seçilmiş ve çalışmanın ilk aşamasında eğitim verisi her üç yöntemle de modellenmiştir. Bir saat sonraki ışıınının değeri modellenirken girdi olarak mevcut ışıınının değeri, bir saat önceki ışıınının değeri ve bir saat sonraki extraterrestrial ışıınının değeri kullanılmıştır. Bulutluluk indeksi için, az bulutlu, bulutlu ve çok bulutluya karşılık gelecek şekilde üç aralık belirlenmiştir. Tahmin edici olarak kullanılan üç yöntem ile eğitim verisi modellenmiş ve her bir yöntemin belirlenen her bir bulutluluk indeksi

aralığındaki başarısı incelenmiştir. Seçilen aralıklarda daha başarılı yöntemler belirlendikten sonra, bulutluluk indeksi zaman serisi yapay sinir ağları ile modellenmiştir. Sonuç olarak hibrit tahmin algoritmasında önce yapay sinir ağları ile bulutluluk indeksi tahmin edilir, sonra tahmin edilen bulutluluk indeksinin yer aldığı aralıkta en başarılı model kullanılarak gelecek güneş ışıınımı değeri tahmin edilir. Deneysel sonuçlar, önerilen hibrit yöntem ile modellerin bireysel olarak kullanıldığı duruma göre daha başarılı tahminler yapıldığını göstermektedir.

2022, xi + 64 sayfa

Anahtar Kelimeler: Güneş Işınımı, Tahmini Algoritması, Hibrit Yöntem, Yapay Sinir Ağları, Ridge Regresyon.

ABSTRACT

M.Sc. Thesis

A HYBRID METHOD DESIGN THAT CONSIDERS DIFFERENT INSOLATION CONDITIONS FOR SOLAR RADIATION FORECASTING

Fatimetou H'MEÏNDE MAHAM

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Renewable Energy Systems

Supervisor: Asst. Prof. Emre AKARSLAN

The world's ever-increasing population and developing technology cause the demand for energy to increase continuously. The usage of clean energy sources has become a necessity in order to satisfy both environmental sensitivity and increasing energy demands. Although solar energy is one of the most important of these sources, the amount of energy produced also varies because of the variable and intermittent nature of the radiation. As a consequence, in order to determine the amount of energy to be produced from the sun and plan production, the solar radiation value must first be determined correctly. In this study, a hybrid method for predicting solar radiation is proposed, wherein the prediction model is determined based on the clearness index. The study used two-year (2013-2014) solar radiation data of the province of Mardin obtained from the Turkish State Meteorological Service (TSMS). The data were divided into two parts: training and testing, with solar radiation data from 2013 used for training and 2014 utilized for testing. As predictors, Artificial neural networks, NARX networks, and Ridge regression methods were used, and the training data were modeled with all three approaches in the first stage of the study. While modeling the irradiance value one hour later, the current irradiance value, the irradiance value one hour ago, and the extraterrestrial irradiance value one hour later were used as inputs. The clearness index was determined into three ranges; slightly cloudy, cloudy, and mostly cloudy. The training data were modeled with three methods used as estimators, and the success of each method was examined in each defined clearness index range. After determining the

more successful methods in the selected intervals, the clearness index time series was modeled using artificial neural networks. As a result, in the hybrid prediction algorithm, the clearness index is first estimated using artificial neural networks, and then the future solar radiation value is predicted by using the most successful model within the predicted clearness index range. Experimental results show that more successful predictions are made with the proposed hybrid method than when models are used individually.

2022, xi + 64 pages

Keywords: Solar Radiation, Prediction Algorithm, Hybrid Method, Artificial Neural Networks, Ridge Regression.

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Emre AKARSLAN'a, araştırma ve yazım süresince yardımlarını esirgemeyen Sayın Şeyma YETKİN'e her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerinden dolayı aileme teşekkür ederim.

Fatimetou H'MEİNDE MAHAM
AFYONKARAHİSAR. 2022

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	ii
TEŞEKKÜR	vi
İÇİNDEKİLER DİZİNİ	vii
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xi
RESİMLER DİZİNİ	xii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	4
3. MATERYAL ve METOT	14
3.1 Extraterrestrial Radyasyon	15
3.2 Bulutluluk İndeksi (Clearness index)	18
3.3 Yapay Sinir Ağ (YSA)	21
3.3.1 Yapay Sinir Ağlarının Sınıflandırılması	23
3.3.1.1 Besleme Türüne Göre Yapay Sinir Ağları	24
3.3.1.2 Öğrenme Yöntemlerine Göre YSA'lar	25
3.3.2 Tahmin Problemleri için Yapay Sinir Ağları	26
3.4 Ekzojen Girdili Doğrusal Olmayan Otoregresif Modeller (NARX)	26
3.5 Ridge Regresyon	29
3.6 Hibrit Metot	32
4. DENEYSEL ÇALIŞMA	34
4.1 Veri Setlerinin Oluşturulması	34
4.2 Değerlendirme Metrikleri	35
4.3 Güneş Işınımının Modellenmesi	36
4.4 Clearness İndex'in Modellenmesi	49
4.5 Hibrit Yöntemin Oluşturulması	50
5. TARTIŞMA ve SONUÇ	54
6. KAYNAKLAR	56
ÖZGEÇMİŞ	64

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

CO ₂	Karbondiyoksit
R ²	Regresyon Katsayısı
W	Watt (Güç Birimi)
H ₀	Extraterrestrial Radyasyon
K _T	Clearness Index
MJ	Megajoul
Ω	Ohm
λ	Lambda
V	Volt (Gerilim Birimi)
m ²	Metrekare
Φ	Phi
δ	Delta

Kısaltmalar

AI	Artificial Intelligence (Yapay Zeka)
ARMA	Autoregressive Moving Average (Oto regresif Hareketli Ortalama)
BP	Backpropagation (Geri Yayılım)
CGP	Polaribiere Conjugate Gradient (Polaribiere Eşlenik Gradyan)
DMPE	Daily Mean of the Power Error (Güç Hatasının Günlük Ortalama)
EMD	Empirical Mode Decomposition (Ampirik Mod Ayrıştırma)
ESSS	Exponential Smoothing State Space (Üstel Düzeltme Durum Uzaı)
FV	Fotovoltaik (PV)
GD	Gradient Descent (Gradyan İniş)
LMD	Local Mean Decomposition (Yerel Ortalama Ayrıştırma)
LSSVM	Least Squares Support Vector Machine (En Küçük Kareler Destek Vektör Makinesi)
LM	Levenberg Marquardt
MSE	Mean Square Error (Ortalama Kare Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
ML	Machine Learning (Makine Öğrenmesi)
MLPNNs	Multilayer Perceptron Neural Networks (Çok Katmanlı Algılayıcı Sinir Ağlar)
MLP	Multi Layer Perceptron (Çok Katmanlı Yapay Sinir Ağı Modeli)
MBE	Mean Absolute Bias Error (Mutlak Eğilim Hata Ortalaması)
NARX	Nonlinear Autoregressive Exogenous (Doğrusal Olmayan Oto regresif Ekzojen)
RP	Resilient Backpropagation (Esnek Geri Yayılım)
RR	Ridge Regresyon

Kısaltmalar(Devam)

RFR	Random Forest Regressor
RMSE	Root Mean Square Error (Ortalama Hata Karesinin Karekökü)
SCG	Scaled Conjugate Gradient (Ölçeklendirilmiş Eşlenik G radyan)
SARIMA	Seasonal Autoregressive Integrated Moving Average
SOM	Self-Organizing Map
SI	The International System of Units (Uluslararası Birimler Sistemi)
Trainbr	Bayesian Regulation Backpropagation (Bayesci Düzenleme Geri Yayılımının)
Trainlm	Levenberg-Marquardt Backpropagation Trainoss (Levenberg-Marquardt Geri Yayılım Trenosu)
YSA	Yapay Sinir Ağları



ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Mardin ili 2013 yılı saatlik güneş radyasyonu grafiği	14
Şekil 3.2 Dünya dışı güneş radyasyonunun yılın zamanına göre varyasyonu	16
Şekil 3.3 Mardin ili için hesaplanan saatlik extraterrestrial radyasyon grafiği	18
Şekil 3.4 Mardin ili 1 yıllık bulutluluk indeksi verileri grafiği	21
Şekil 3.5 Bir nöronun şematik diyagramı	23
Şekil 3.6 Aktivasyon Fonksiyonları	24
Şekil 3.7 İleri Beslemeli YSA Blok Diyagramı	25
Şekil 3.8 Geri Beslemeli YSA Blok Diyagramı.....	26
Şekil 3.9 Hibrit Yöntemin Prensip Şeması	35
Şekil 4.1 Mardin ili 2013 yılı saatlik güneş radyasyonu grafiği	37
Şekil 4.2 Mardin ili için hesaplanan saatlik extraterrestrial radyasyon grafiği.....	38
Şekil 4.3 YSA Ağının Oluşturulduğu Parametreler	40
Şekil 4.4 Oluşturulan YSA'nın Yapısı	41
Şekil 4.5 Oluşturulan YSA'nın Eğitim Aşaması.....	42
Şekil 4.6 Oluşturulan Ağın Eğitim Performansı	43
Şekil 4.7 Oluşturulan Ağın Regresyon Doğruları	44
Şekil 4.8 YSA testinin grafiği	45
Şekil 4.9 NARX Ağının Oluşturulduğu Parametreler.....	47
Şekil 4.10 Oluşturulan NARX'ın Yapısı	48
Şekil 4.11 Oluşturulan NARX'ın Eğitim Aşaması	49
Şekil 4.12 Oluşturulan Ağın Eğitim Performansı	50
Şekil 4.13 Oluşturulan Ağın Regresyon Doğruları	51
Şekil 4.14 NARX testinin grafiği.....	52
Şekil 4.15 Ridge Regresyon Parametreleri	53
Şekil 4.16 Ridge Regresyon testinin grafiği	53
Şekil 4.17 Hibrit Yöntemin Oluşturulması	56
Şekil 4.18 Ölçülen ve tahmin edilen değerleri karşılaştıran grafikler.....	58

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Hibrit Yöntem Algoritması için Pseudo Kodu	36
Çizelge 4.1 Sinir Ağı Performans İşlevleri	39
Çizelge 4.2 YSA Ağıının sonuçları.....	41
Çizelge 4.3 NARX'ın sonuçları	47
Çizelge 4.4 Ridge Regresyon sonuçları	53
Çizelge 4.5 Clearness index sonuçları	54
Çizelge 4.6 Korelasyon sonuçları	55
Çizelge 4.7 Modellerin sonuçları	55
Çizelge 4.8 YSA-NARX-RR modellerinin ve hibrit modelin tahmin sonuçlarının bir özet.....	57

RESİMLER DİZİNİ

Sayfa

Resim 3.1 NARX tekrarlayan sinir ağı mimarisi.....	29
---	----



1. GİRİŞ

Günümüz dünyasının temel sorunlarından biri olan küresel ısınma ve iklim değişikliğinin temel nedenleri insan kökenlidir (IPCC, 2013: 13). İnsanın, ihtiyaçlarını karşılamak uğruna gerçekleştirdiği faaliyetler doğaya ve gelecek kuşakların yaşam kalitesine zarar vermektedir. Dünya nüfusundaki hızlı artış, sanayileşme faaliyetleri, teknolojik yenilikler, yaşam seviyesindeki yükselme ve hızla artan tüketim harcamaları yoğun bir enerji talebine yol açmaktadır. Her geçen gün artan talebi karşılamak için gerçekleştirilen enerji üretiminde, daha rahat bulunur ve az maliyetli olması nedeniyle büyük ölçüde geleneksel fosil yakıtlar (yenilenemez kaynaklar) tercih edilmektedir. Fosil yakıtlar olarak adlandırılan kömür, petrol ve doğalgaz gibi kaynaklar yenilenebilir değildir, çevreye büyük zararları vardır ve özellikle havadaki oksijen miktarını düşürdüklerinden havanın kirlenmesine neden olurlar. Petrol, doğalgaz ve kömür gibi fosil yakıtlara dayalı enerji kullanımından ortaya çıkan karbondioksit (CO₂) ve benzeri sera gazları, ortalama yüzey sıcaklığının artmasına neden olmaktadır. Bu durum, kaçınılmaz olarak iklim değişikliğine ve biyolojik çeşitliliğin azalmasına yol açmaktadır. Aynı zamanda tehdit altındaki birçok bitki ve hayvan türünün, suyun ve havanın temizlenmesine, sel ve erozyonun önlenmesine, tarımsal üretimin ve gıda zincirinin devamlılığına olumlu etkide bulunduğu düşünülürse, küresel ölçekte yeni felaketlerin ortaya çıkabileceğinden söz edilebilir (IEA, 2013: 4). Bu gibi nedenlerle, çevre konularına karşı artan insan duyarlılığı, dikkatleri yenilenebilir enerji kaynaklarına çekmiştir (Jafarzadeh vd. 2012, Kinloch vd. 1982). Çünkü yenilebilir enerji kaynakları fosil kaynaklara nazaran çevre dostudurlar ve sürekli olarak kendilerini yenilerler.

Yenilenebilir enerji, sağlıklı kalkınma ve temel insan ihtiyaçlarının karşılanması için vazgeçilmezdir. Ekonomik büyüme ve toplumsal refahın temel girdilerinden birisi ve hatta en başta gelenin enerji olduğu savı, küresel düzeyde de kabul görmektedir. Enerjinin, geri dönülmez çevresel tahribata yol açmadan, ekolojik dengeyi bozmadan ve kuşaklararası adalet anlayışına uygun bir biçimde kullanım hedeflerini içeren “sürdürülebilir enerji” kavramını, uluslararası toplumun benimsediği ortak bir politika ilkesi olarak nitelendirmek mümkündür (Flavio vd. 2020). Sürekli artan enerji talebi ve

fosil yakıt kullanımından kaynaklanan küresel ısınmanın önlenmesine yönelik uluslararası çalışmalar, daha “temiz” olduğu kabul edilen yenilenebilir enerji kaynak (hidroelektrik enerji, jeotermal enerji, rüzgâr enerji, bio-kütle, bio-yakıt ve güneş enerji) kullanımının zorunlu olduğunu ortaya koymaktadır. Bu enerji kaynağı ücretsiz, temiz ve yıl boyunca çoğu yerde yeteri miktarda mevcuttur. Fosil yakıtlar ise tükenebilir, çevreyi kirletir ve azaldıklarında enerji maliyetleri artar. Dolayısıyla, bugün birçok ülke artan enerji ihtiyacını karşılamak ve fosil yakıtlarının ortaya çıkardığı olumsuz etkileri azaltabilmek amacıyla yenilenebilir enerji kaynaklarına yönelmektedir (Owusu vd. 2016). Son yıllarda elektrik üretiminde yenilenebilir kaynak kullanımının arttığı ve gelecek dönemlerde artmaya devam edeceği gözlenmektedir. Küresel olarak toplam enerji üretiminde yenilenebilir kaynak kullanımının payı 2006 yılında %19 iken, bu oranın 2020'nin ilk çeyreğinde yaklaşık %28'e yükseldiği görülmektedir (O'Neill 2020).

Yenilenebilir enerji kaynaklarının kullanımı ile bir taraftan elektrik ihtiyacı karşılanırken bir taraftan da küresel anlamda iklim değişikliğinin önlenmesine yardımcı olunabilecektir. Bu anlamda güneş enerjisi; yüksek potansiyeli, kullanım kolaylığı ve çevre dostu olması nedenleriyle yenilenebilir enerji kaynakları içinde ön plana çıkmaktadır (Fatih ve Mehmet 2018). Bu faktörler nedeniyle, araştırmacılar güneş enerjisi ile ilgili konulara, özellikle güneş ışıınım tahminine daha derinlemesine odaklanmışlardır. Güneş enerjisinden elde edilecek olan faydanın belirlenmesindeki en önemli parametrelerden bir tanesi güneş ışıınım verisidir. Güneş ışıınımı verileri, belirli bir süre boyunca Dünya yüzeyindeki bir konuma ne kadar güneş enerjisinin ulaştığı hakkında bilgi verir. Bu veriler, güneş enerjisi kullanımına ilişkin etkili araştırmalar için gereklidir. Güneş ışıınımının tahmini, güneş enerjisinden elektrik üretiminde büyük öneme sahiptir ve fotovoltaik güç sistemlerinin boyutlandırılmasına yardımcı olur. Bir fotovoltaik (FV) enerji santralinden üretilen güç, doğrudan yüzeyine düşen güneş ışıınımı ile ilgilidir. Yatay bir yüzeydeki ideal güneş ışıınımın değerleri güneş geometrisine göre tahmin edilebilirken, bu değerler yağmur ve bulutlar gibi atmosferik olaylarla değişiklik gösterir. Bu tür doğal değişiklikler, güneş ışıınımın tahmini zorlaştırır (Khatib vd. 2012). Ancak güneş ışıınımının başarılı bir şekilde tahmin edilmesi, daha etkin bir enerji planlaması ve yönetimi için zorunludur. Bu sebeple,

arařtırmacılar güneř ıřınıının kısa, orta ve uzun vadede daha doęru tahmin edilebilmesi için farklı yöntemler geliřtirmek üzerine çalışmaktadırlar.

Bu tez çalışmasında, saatlik güneř ıřınım tahmini için yapay sinir aęları, NARX (Nonlinear Autoregressive Network with Exogenous Inputs) ve Ridge Regresyon yöntemlerinin kombinasyonundan oluşan hibrit bir yöntem tasarlanmış ve bu yöntemin başarısı irdelenmiştir. Gerçekleřtirilen çalışmalarda, Meteoroloji Genel Müdürlüğünden temin edilen Mardin iline ait güneř ıřınım verileri kullanılmıştır. Eğitim verisi üzerinde öncelikle her bir yöntemin başarısı incelenmiş, sonrasında ise, havanın bulutluluk durumunu temsil eden bulutluluk indeksi deęerleri hesaplanmıştır. Her bir yöntemin farklı bulutluluk indeksleri aralığında güneř ıřınım tahmin performansları incelenmiş ve bu performans deęerleri dikkate alınarak hibrit bir yöntem tasarlanmıştır.

2. LİTERATÜR TARAMASI

Güneş enerjisi, dünyanın en önemli enerji kaynaklarından biridir ve çevre açısından temiz bir enerji kaynağı özelliği taşıdığı için, birçok araştırmacı bu konuyu çeşitli başlıklar altında incelemiştir. Güneş enerjisi ile ilgili araştırmalar 20. yüzyılın ilk çeyreğinde başlamış ve ilk olarak güneş ışıının güneşe maruz kalma süresine göre tahmini üzerinde çalışılmıştır (Yavuz Selim 2018). Güneş radyasyonu tahmininin gerekliliği birkaç faktörle ilişkilendirilmektedir. Güneş radyasyonunun fotovoltaiik (FV) güç üretimi üzerinde önemli bir etkisi vardır. Elektrik, konsantre olmayan FV modüller veya konsantre güneş enerjisi (CST) sistemleri kullanılarak güneş radyasyonundan üretilebilir (Sanan vd. 2020). Güneş enerjisinin verimli kullanımı ve dönüşümü için güneş radyasyonu verileri sürekli ve doğru bir şekilde bilinmelidir. Ayrıca Güneş enerjisine dayalı projelerin geliştirilmesi için belirli bir konumdaki güneş radyasyonunun yoğunluğu hakkında doğru bilgi elde etmek gerekmektedir. Bu bilgiler, bir projenin tasarımında, maliyet analizinde ve verimliliğinin hesaplanmasında kullanılır. Güneş ışıının tahmini, güneş enerjisi santrallerinin işletilmesi ve yönetimi açısından oldukça önemlidir. Güneş ışıının ölçülen değerleri, global güneş radyasyonu, dağınık (difüz) güneş radyasyonu veya direkt güneş radyasyonu şeklinde olabilir. Farklı uygulamalar için bu değerlerden bazıları diğerlerinden daha önemli olabilir. Güneş ışıının verilerine, fotovoltaiik veya termal güneş sistemlerinin performansını tahmin etmek için ihtiyaç duyulmaktadır. Güneş ışıının verilerine, aynı zamanda, güneş enerjisi jeneratörlerinin dağıtımını yönetebilmek için elektrik dağıtım şirketleri ihtiyaç duymaktadırlar (Ayodele vd. 2016). Buna ek olarak, gelecekte güneş radyasyonunu bilmenin bir başka avantajı, elektrik şebekesindeki güneş enerjisinin kontrolünü optimize etmede yatmaktadır, bu da gelecekte Akıllı şebeke alanında kullanılabilecek elektrik üretim pazarında olumlu bir performans sağlayabilir (Rabehi vd. 2020).

Güneş enerjisi şebekeye bağlı olduğunda büyük ölçekte üretilebilir, enerji talebini ve arzını dengelemek için güneş enerjisi tahminine ihtiyaç duyulmaktadır. Bu nedenle, büyük ölçekte enerji üretmek amacıyla tasarlanmış veya enerji talebini ve arzını dengelemek için şebekeye bağlı olan güneş enerjisi sistemlerinde güneş radyasyonu

tahmini hayati önem taşımaktadır. Modern çalışmalar, birçok güneş sisteminin açık/bulutlu zaman aralıklarında kapalı/açık bir şekilde çalışabileceği sonucuna varmıştır. Bu yönüyle, güneş radyasyonlarını farklı zaman aralıklarında tahmin etmek önemlidir (Atika Qazi vd. 2015). Yüksek performanslı bir güneş enerjisi üretim sistemi, büyük ölçüde çıktı gücünün tahminine bağlıdır, çünkü bu veriler bu sistemlerin tasarımını ve boyutlandırılmasını destekleyebilir. Bu konsept altında, küresel güneş radyasyonunun tahmin modelleri iki ana kategori altında geliştirilmektedir: uydu bulut görüntüleri ve makine öğrenmesi (ML) modelleri (Diagne vd. 2014).

Güneş enerjisi uygulamalarında, sistem tasarımı ve projelendirmesinde o bölgenin güneş radyasyonu verileri ve bileşenlerinin bilinmesi gerekmektedir. Ancak güneş radyasyonu ölçüm elemanlarının maliyet, bakım ve kalibrasyon gereksinimleri nedeniyle birçok yerde radyasyon ölçümleri yapılamamaktadır. Güneş radyasyonu verilerinin ölçülemediği yerlerde uygun korelasyonlar oluşturularak, bu veriler belirlenebilir. Güneş radyasyonu miktarını belirlemek için birçok deneysel model geliştirilmiştir. Bu modeller, güneşlenme süresi, maksimum ortam sıcaklığı, bağıl nem, enlem, boylam, yılın günü, günlük açık gökyüzü küresel radyasyonu, toplam bulut örtüsü, sıcaklık, bulutluluk indeksi, yükseklik, ortalama sıcaklık, ortalama bulutluluk, ortalama rüzgar hızı, atmosferik basınç, referans bulutluluk indeksi, ortalama difüz radyasyon, dünya dışı radyasyon, buharlaşma ve toprak sıcaklığıdır. Güneş ışığı süresi çoğu yerde kolaylıkla elde edilebilir ve ölçülür, bu nedenle genellikle güneş radyasyonunun modellenmesi için kullanılır (Bakırcı 2009, Ahmad 2011). Ayrıca son yıllarda, global güneş radyasyonu ve yayılmış radyasyon verileri, iklim analizinde ve çeşitli teknik uygulamalarda önemli bir rol oynamıştır. Nitekim, güneş radyasyonu elde etmenin en kesin yöntemi, belirli bir alan için doğrudan zemin ölçümlerinin kullanılmasıyla mümkündür (Selmin ve Aycan 2019).

Dünya yüzeyine ulaşan güneş radyasyonu, bir yerin iklim koşullarına göre değişir. Bu durum birçok araştırmacıyı, farklı yerel iklim koşulları altında güneş ışıınımını tahmin etmek için farklı modeller bulmaya teşvik etmiştir. Ek olarak, tahmin doğruluğunu iyileştirmek için güneş radyasyonunun doğrusal olmayışını ele alma ihtiyacı, yeni tahmin modellerinin geliştirilmesine yol açmıştır. Ayrıca literatürden, araştırmacılar

tarafından geliştirilen çeşitli tahmin modellerinin, her birinin kendine özgü avantajları ve zorlukları olan dört genel kategoriye ayrılabilceği görölmektedir. Bu kategoriler şu şekilde ifade edilebilir: regresyon tabanlı modeller, yapay zeka (AI) modelleri, istatistiksel tabanlı modeller ve uydu görüntü modelleri (Ayodele vd. 2016).

Yapay sinir ağı teknikleri (YSA), geleneksel tekniklere iyi bir alternatif yöntemdir, güneş sistemlerinin tasarlanması ve güneş radyasyonlarının tahmin edilmesi gibi bir dizi güneş enerjisi uygulamasında kullanılır (Yadav vd. 2014). Literatürde güneş radyasyonu tahmini için, yapay sinir ağlarının kullanıldığı birçok çalışma bulunmaktadır (Hepbasli ve Alsuhaibani, 2011). Assas vd. (2014), yaptıkları çalışmada, meteorolojik değişkenleri kullanarak yatay bir yüzeyde günlük küresel güneş radyasyonunu tahmin etmek için bir dizi yapay sinir ağı modeli (YSA) sunmaktadırlar. Girdi verilerini sınıflandırmazlar, bunun yerine, birkaç meteorolojik parametrelerin tahmin sonuçları üzerindeki etkisini göz önünde bulundurmak amacıyla dört giriş özelliği kombinasyonu ile dört sinir ağını eğitirler. En iyi performansın, gün bilgisi, atmosferin tepesindeki ortalama günlük güneş radyasyonu, maksimum güneşlenme saatleri, ortalama günlük hava sıcaklığı, ortalama günlük bağıl nem ve rüzgar hızı girdileri kullanılarak elde edildiği sonucuna varmışlardır. Ayrıca sonuçlar, tahmin performansını etkileyen en önemli özelliğin bağıl nem olduğunu göstermektedir. Yadav ve Chandel (2012), farklı iklim koşullarına sahip 12 Hint istasyonundan elde edilen güneş radyasyonunun tahmini için YSA'yı kullanmışlardır. Model, tahmin için enlem, boylam, deniz seviyesinden yükseklik, güneş ışığı saatleri ve güneş radyasyonu gibi giriş parametreleri kullanmışlar, YSA'yı eğitmek için Levenberg Marquardt (LM) algoritmasını tercih etmişlerdir. Geliştirilen YSA modeli ile Hindistan bölgesi için 0.0486 ile 3.562 arasında değişen farklı RMSE değerleri ile tahminler gerçekleştirmişlerdir.

Linares-Rodríguez vd. (2011), giriş olarak enlem, boylam, yılın günü, günlük açık gökyüzü küresel radyasyonu, toplam bulut örtüsü, toplam su buharı ve ozon verilerini kullanarak İspanya bölgesine ait güneş radyasyonunu tahmin etmek için YSA yöntemini kullanmışlardır. Tahmin edilen değerler ile ölçülen değerler arasındaki RMSE'nin %13,52 (eğitim istasyonları için) ile %14,20 (test istasyonları için) arasında değiştiği

bulunmuştur. Endülüs'te (İspanya) model doğrulaması için 83 metroloji istasyonundan alınan 9 yıllık ölçülen veriler kullanılmıştır.

Mohandes vd. (1998), Suudi Arabistan'daki küresel güneş radyasyonunu enlem, boylam, yükseklik ve güneş ışığı süresinin bir fonksiyonu olarak modellemek için YSA'yı kullanmışlardır. Geri yayılım algoritması (BP), çok katmanlı ileri beslemeli sinir ağlarının farklı konfigürasyonunu eğitmek için tercih edilmiştir. 4 girişli olan modelin gizli katmanında 10 nöron kullanılmış ve test istasyonlarında 6.5 ile 19.1 arasında değişen MAPE değerleri elde edilmiştir. AI-Alawi ve AI-Hinai (1998), Seeb bölgesi küresel radyasyonu tahmin etmek için çok katmanlı bir ileri beslemeli ağ, geri yayılım (BP) eğitim algoritması uygulamışlardır. Girdi olarak lokasyon, ay, ortalama basınç, ortalama sıcaklık, ortalama buhar basıncı, ortalama bağıl nem, ortalama rüzgar hızı ve ortalama güneş ışığı parametreleri kullanılmış, 5,43 ile 7,30 arasında değişen MAPE değerleri elde edilmiştir.

Voyant vd. (2011), YSA kullanarak Fransa'nın Korsika Adası'nda günlük güneş radyasyonunu tahmin etmişlerdir. Yazarlar dikkate alınacak endojen ve ekzojen girdileri belirlemek için korelasyon kriterini kullanmışlardır. Güneş radyasyonunun açık gökyüzü modeli için dört endojen zaman gecikmesini dikkate almışlardır. Birkaç meteorolojik parametreden, dışsal girdi olarak yalnızca üçünü seçmişlerdir: bağıl nem, güneş ışığı süresi ve bulut örtüsü. Bu tekniği, Korsika Adası'nda bulunan iki farklı sahada uygulamış ve tahmin yöntemlerinin başarılarını karşılaştırmışlardır. Fadare (2009), Nijerya'daki güneş enerjisi potansiyelinin tahmini için YSA tabanlı bir model geliştirmiştir. MATLAB için nöral araç kutusu kullanarak standart çok katmanlı, ileri beslemeli, geri yayımlı sinir ağlarını farklı mimari ile uygulamış ve modelin güneş uygulamalarının ön tasarımı ve güneş radyasyonu tahmini için kolayca kullanılabileceğini belirtmişlerdir.

Premalatha ve Valan (2016), Hindistan'daki aylık ortalama küresel güneş radyasyonunu tahmin etmek için bir YSA modeli geliştirmiştir. Her biri dört geri yayılım (BP) algoritmasına sahip iki farklı yapay sinir ağı modeli kullanılmış; gradyan iniş (GD), Levenberg – Marquardt (LM), ölçeklendirilmiş eşlenik gradyan (SCG) ve esnek geri

yayılım (RP) algoritması eğitilmiş ve test edilmiştir. Hindistan'ın coğrafyasını kapsayan beş istasyondan meteorolojik veriler, ağı eğitimi ve test edilmesi için 10 yıllık bir süre boyunca toplanmıştır. Eğitim ve test veri kümeleri için R^2 değerleri %90'dan yüksektir, bu da güneş radyasyonunun değerlendirilmesi için modelin yüksek güvenilirliğini göstermektedir. Sözen ve Arcaklioğlu (2005), YSA kullanarak Türkiye'deki güneş enerjisi potansiyelini tahmin etmişlerdir. YSA modelinde, ölçeklendirilmiş konjugat gradyanı (SCG), Polaribiere konjugat gradyanı (CGP), Levenberg Marquardt (LM), öğrenme algoritması ve lojistik transfer fonksiyonu kullanılmıştır. Coğrafi koordinatlar, ortalama güneş ışığı süresi, ortalama sıcaklık ve ay parametreleri girdi olarak ve güneş radyasyonu parametresi çıktı olarak alınmıştır. MAPE %3.832'den azdır, bu nedenle tahmin edilen güneş kaynağı değerlerinin tüm aylar için gerçek değerlere çok yakın olduğu söylenebilir.

Koca vd. (2011), Anadolu'nun Akdeniz bölgesindeki yedi şehrine ait güneş radyasyonunun tahmini için YSA tabanlı bir model geliştirmişlerdir. Tahminde en iyi YSA konfigürasyonunu bulmak için girdi parametreleri olarak; enlem, boylam, yükseklik, aylar, ortalama sıcaklık, ortalama bulutluluk, ortalama rüzgar hızı ve güneş ışığı süresinin altı farklı kombinasyonu kullanılır. Çalışmada güneş radyasyonu tahmininde girdi parametre sayısının etkili olduğu gösterilmiştir. Lazzús vd. (2011), Şili'deki La Serena şehrinde saatlik küresel güneş radyasyonunu tahmin etmek için girdi olarak rüzgar hızı, bağıl nem, hava sıcaklığı ve toprak sıcaklığı verilerini kullanmış ve bu veriler YSA ile modellenmiştir. Saatlik küresel güneş radyasyonu ile meteorolojik veriler arasında güçlü bir korelasyon olduğunu gösteren R^2 'nin % 94 olduğu bulunmuştur. Rehman ve Mohandes (2009), Suudi Arabistan'daki Abha şehri için yaygın güneş radyasyonunu tahmin etmek için dört girdili (gün, maksimum hava sıcaklığı, ortalama hava sıcaklığı, bağıl nem) bir YSA modeli kullanmışlardır. Ortalama kare hatası (MSE) olarak elde edilen sonuçlar, bağıl nem ve günlük ortalama sıcaklık kullanımının, diğer kombinasyonlardan daha iyi performans gösterdiğini ortaya koymuştur.

Literatürde güneş radyasyonunu tahmin etmek için, Doğrusal Olmayan Otoregresif Ekzojen (NARX) modeller de kullanılmıştır. NARX, biri giriş ve diğeri çıkış için olmak

üzere iki gecikmeli doğrusal ARX modelinden oluşur. Çok katmanlı algılayıcıya ve yinelenen bağlantılara dayanır. Araştırma çalışmalarında, PV gücü tahmini, elektrik fiyatları tahmini ve hava kirliliği tahmini gibi uygulamalarda kullanılmıştır (Pisoni vd. 2009, Arash vd. 2009). Bu model, zaman serileri tahmininin yanı sıra doğrusal olmayan dinamik sistem modellemesi için de kullanılır. Diğer sinir ağı türleriyle karşılaştırıldığında, NARX modeli iyi öğrenme, hızlı yakınsama ve daha iyi genelleme karakteristiğine sahiptir (Diaconescu 2008).

Bir yandan güneş radyasyonunun bir zaman serisi olduğu, diğer yandan, NARX sinir ağının zaman serilerinin iyi bir öngörücüsü olduğu düşünüldüğünde (Mohanty and Patra 2015), bu yöntem güneş ışıınım tahmin çalışmalarında kullanım için oldukça uygundur. Boussaada vd. (2018), yatay bir yüzey üzerinde doğrudan güneş radyasyonu tahmini için bir NARX sinir ağı modeli önermektedir. Bu araştırma çalışmasının ana bulgusu, sinir ağının eğitim aşamasının bulut örtüsü ve güneş özellikleri gibi çeşitli parametreler dikkate alınarak periyodik olarak gerçekleştirilmesidir. Gerçekleştirilen çeşitli simülasyonlarda ortalama kare hatası (MSE) ve güç hatasının günlük ortalaması (DMPE) hataları gibi kriterler ile sonuçlar değerlendirilmiştir. Sonuç olarak, en iyi performans, gizli katmanda 15 nöronun bulunduğu, transfer fonksiyonu olarak *tansig* (Tangent-Sigmoid) fonksiyonunun kullanıldığı bir NARX modeli ile elde edilmiştir.

Mohanty ve Patra (2015), Hindistan'ın Bhubaneswar kentinde güneş radyasyonunu tahmin etmek için, NARX modelini kullanan bir sistem önermişlerdir. NARX yaklaşımında, güneşlenme süresi, sıcaklık, nem gibi meteorolojik parametreler girdi olarak kullanılmıştır. 2002-2005 dönemine ait veriler NARX ağının eğitilmesi için kullanılırken, 2006 yılı verileri test için kullanılmıştır. Sonuçlar ortalama kare hatası ve regresyon katsayısı temelinde değerlendirilmiştir. Levenberg Marquardt algoritması (*trainlm*) ile eğitilmiş NARX modelinin, daha düşük MSE ile daha iyi sonuçlar verdiğini göstermektedir. Mohammed ve Eman (2013), Ürdün, Amman'da saatlik güneş radyasyonu ile ilgili tahminler yapmak için NARX modelini kullanmışlardır. 2004-2007 yılları için meteorolojik veriler eğitim için kullanılırken, 2008 yılı için veriler test için kullanılmıştır. NARX modelinin performansı, R^2 belirleme katsayısı, kök ortalama kare hatası (RMSE) ve ortalama önyargı hatası (MBE) gibi istatistiksel

analiz kullanılarak incelenmiş ve değerlendirilmiştir. Levenberg-Marquardt öğrenme algoritmasının kullanıldığı çalışmada, tahmin verileri ile ölçülen veriler arasındaki karşılaştırmalı analiz, NARX modelinin giriş ve çıkış değişkenleri arasındaki ilişkiyi tanıma ve saatlik güneş radyasyonunu doğru bir şekilde tahmin etme yeteneğine sahip olduğunu göstermiştir. Bu nedenle NARX modeli, ileri besleme tekniğinden daha doğru sonuçlar üretir.

Sansa ve Bellaaj (2018), NARX modelinin özellikle düşük güneş radyasyonu dalgalanmaları için güneş radyasyonunu tahmin etmedeki etkinliğini kanıtlamıştır. Güneş radyasyonunu tahmin etmek için bir tür dinamik sinir ağı olarak NARX kullanmışlardır. Bu araştırmada, güneş radyasyonu iki farklı sinir ağı, statik ağ ve NARX modeli kullanılarak tahmin edilmektedir. Simülasyon sonuçları sunulmuş ve statik sinir ağına kıyasla NARX modelinin güneş radyasyonunu tahmin etme etkinliği özellikle düşük güneş radyasyonu dalgalanmaları için kanıtlanmıştır. NARX modeli, çıktının kendisine ek tahmin gücü veren doğrudan geri beslemesinin varlığı ile karakterize edilir.

Literatürde güneş ışıınım tahmini için Ridge regresyonun kullanıldığı çalışmalar da bulunmaktadır. Ridge regresyonu, doğrusal regresyonun bir varyantıdır ve aynı zamanda λ değerlerini değiştirerek model katsayılarının değiştirilebileceği regularizasyon olarak da bilinir (Hoerl ve Kennard 1970, Khalaf ve Shukur 2005). Sharma ve Bhatt (2019) ridge regresyonu, hava durumu verilerini kullanarak günlük gelen güneş enerjisi çıktısını tahmin etmek için kullanılmıştır. Zameer Shahid vd. (2020), doğrusal olmayan regresyon modelleri, Lineer regresyon, Ridge regresyon, Lasso regresyon, YSA ve Random Forest Regressor (RFR) yöntemlerinin güneş enerjisi tahminindeki başarıları karşılaştırmışlardır. Bu araştırmada, ridge regresyon ile random forest'a kıyasla daha iyi sonuçlar elde edilmiştir.

Yukarıda sunulan literatür bilgileri farklı yöntemlerin farklı şartlar altında farklı performanslar sağlayabileceğini göstermektedir. Bu durum araştırmacılara farklı modelleri birleştirmeleri konusunda ilham kaynağı olmuştur. Bu füzyon, bireysel yöntemlerden daha iyi performans gösterebilen sağlam bir model sunar (Al-Enezi vd.

2010). Öte yandan, hibrit modeller iki veya daha fazla tahmin modelinin birleşimidir. Bu nedenle, her modelin özelliği aktarıldığından doğruluğu da artmaktadır.

Dong vd. (2014), güneş radyasyonu tahmini için uydu görüntü analizini üstel yumuşatma durum uzayı (ESSS: Exponential Smoothing State Space) modeli ve yapay sinir ağı (YSA) ile birleştirerek yeni bir hibrit yöntem önermiştir. Bir hava durumu bilgisi sağlayıcısı olarak sabit uydular, kendi kendini organize eden harita (SOM) yönteminin bir bulut örtüsü indeksi türetmesine ve analiz etmesine izin verir. Bulut örtüsü endeks tahmini için ESSS modeli kullanılmıştır. Daha sonra, öngörülen bulut örtüsü endeksine dayalı olarak güneş radyasyonunu tahmin etmek için YSA tekniği uygulanmıştır.

Şenkal ve Kaleli (2009) Türkiye'deki 12 şehire ait güneş radyasyonunu tahmin etmek için YSA ve fiziksel model kullanmışlardır. Ağa giriş değerleri enlem, boylam, yükseklik, ay, ortalama dağınık radyasyon ve ortalama ışın radyasyonudur. 9 şehrin verilerinin eğitim, 3 şehrin verilerinin test için kullanıldığı çalışmada hibrit yöntem ile daha başarılı sonuçlar elde edilmiştir. Voyant vd. (2012), Yapay Sinir Ağı (YSA), Otomatik Gerileyen ve Hareketli Ortalama (ARMA) modelinin birlikte kullanımına dayalı orijinal bir teknik önermiştir. Doğrusal olmayan yapısı gereği YSA bulutlu günleri tahmin etmede etkilidir, ARMA teknikleri daha çok bulut oluşumlarının olmadığı güneşli günlerde başarı sonuçlar vermektedir. Bu nedenle, üç hibrit model önerilmiştir: ilki basitçe ARMA'yı ilkbahar ve yaz aylarında 6 ay boyunca kullanmayı ve yılın diğer kısmı için optimize edilmiş bir YSA kullanmayı önerir; ikinci model ilkine eşdeğerdir, ancak mevsimsel öğrenme gerçekleştirilir; son model, önceki saatte meydana gelen hataya bağlı olarak şekillenir. Bu modeller, Akdeniz bölgesindeki beş yer için saatlik küresel radyasyonu tahmin etmek için kullanılmıştır. Sonuçlar her üç hibrit yaklaşımında da başarılı sonuçlar elde edildiğini göstermiştir.

Azimi vd. (2016), güneş radyasyonlarını tahmin etmek için bir zaman serisi analizi, yeni bir kümeleme tekniği, yeni bir küme seçim algoritması ve çok katmanlı algılayıcı sinir ağlarını (MLPNNs) birleştiren hibrit bir tahmin yöntemi geliştirmiştir. Tahmin doğruluğunu artırmak için TB K-ortalamları (Transformation based K-means

algorithm) olarak adlandırılan dönüşüm tabanlı K-ortalama bir algoritma kullanan hibrit bir güneş ışıyım tahmin çerçevesi önermişlerdir. Sonuçlar, hibrit yöntemle yapılan tahminin doğruluk performansının daha iyi olduğunu göstermektedir. Nazaripouya vd. (2016), dalgacık, ARMA ve NARX modeline dayalı bir hibrit yöntem kullanarak bir dakika sonraki güneş radyasyonunu tahmin etmişlerdir. Tahmincinin girdisi olarak yalnızca geçmiş güneş radyasyon değerleri kullanılması planlanmış, bu nedenle dalgacık dönüşümü geçmiş verileri tahmin için uyarlanmış serilere bölmek için kullanılmıştır. Araştırmacılar, dalgacık-ARMA tahmininin hatalarını azaltmak için ARMA konseptini doğrusal bir tahminci olarak ve NARX modelini doğrusal olmayan bir tahminci olarak kullanmışlardır. Geliştirilen hibrit yöntem, bireysel kullanımdan daha başarılı sonuçlar sağlamıştır. Wang vd. (2018), sadece güneş radyasyonunun tarihsel verileri kullanmış ve bu verileri ayırtmışlardır. Bu ayırtma, Yerel Ortalama Ayırtma (LMD) ve Ampirik Mod Ayırtma (EMD) aracılığıyla gerçekleştirilir. Sonuç, bir dizi doğrusal olmayan alt bileşendir, bu nedenle bu alt bileşenler iki doğrusal olmayan tahmin modeli ile modellenmiştir. En Küçük Kareler Destek Vektör Makinesi (LSSVM) ve Volterra modelleri sırasıyla yüksek frekanslı alt bileşenleri ve düşük frekanslı alt bileşenleri tahmin etmek için kullanılmıştır. Nihai sonuç, alt tahmin sonuçlarının birleştirilmesiyle elde edilmiştir. Tikyaa vd. (2018), 2016 yılı için günlük güneş radyasyonunu tahmin etmek için, hibrit SARIMA-NARX-Chaos modelini kullanmışlardır. On altı yıllık eğitim verileri (2000-2015) modele girdi olarak verilmiş ve 2016 yılı verileri test için kullanılmıştır. Önerilen yöntem ile daha başarılı sonuçlar elde edilmiştir.


Yukarıda sunulan literatür taraması incelendiğinde, güneş ışıyım değerinin meteorolojik etkenlere bağlı olarak değişkenlik gösterdiği, bu sebeple güneş ışıyım verisinin doğrusal ve doğrusal olmayan (stokastik) bileşenler içerdiği anlaşılmaktadır. Ayrıca güneş ışıyım modellemesinde kullanılan yöntemlerin farklı karaktere sahip olduğu ve farklı şartlar altında farklı performanslar sergileyebildikleri görülmektedir. Bu kapsamda tahmin başarısını artırmak için hibrit yöntemlerin oluşturulduğu, böyle yapılarda kullanılan yöntemlerin birbirlerinin zayıflıklarının üstesinden geldiği belirlenmiştir. Sunulan tez çalışmasında, bu hususlar dikkate alınarak güneş ışıyım tahmini için hibrit bir yöntem geliştirilmesi hedeflenmiştir. Çalışmada Türkiye Meteoroloji İşleri Genel

Müdürlüğü'nden alınmış, Mardin ili 2013-2014 yıllarına ait güneş ışınlam verileri kullanılmıştır. 2013 yılına ait veriler eğitim, 2014 yılına ait veriler ise test için değerlendirilmiştir. Her biri farklı özelliklere sahip olan 3 farklı yöntem, YSA, NARX ve Ridge regresyon üzerinde incelemeler gerçekleştirilmiştir. Hibrit yöntem oluşturmak için, öncelikle, belirtilen bölgeye ait bulutluluk indeksi verileri hesaplanmıştır. Eğitim için kullanılan veri, üç yöntem ile ayrı ayrı modellenmiş, farklı bulutluluk indeksi altında hangi yöntemin daha başarılı sonuçlar verdiği belirlenmiştir. Hibrit yöntem ise farklı bulutluluk indeksi durumunda, sadece o şartlarda başarılı olan yöntemin kullanılması prensibi ile oluşturulmuştur. Bu kapsamda öncelikle eğitimde kullanılan bulutluluk indeksi verileri YSA ile modellenmiştir. Sonrasında, öncelikle, gelecek saat için bulutluluk indeksi tahmin edilmiş, tahmin edilen değere uygun model ile ise güneş ışınlam değeri tahmin edilmiştir. Sonuçlar farklı değerlendirme kriterleri ile değerlendirilmiş ve yorumlanmıştır.

3. MATERYAL ve METOT

Bu bölümde, tez çalışmasında kullanılan veri seti açıklanarak, kullanılan yöntemler detaylı olarak incelenmiştir. Bu kapsamda ilk olarak çalışmada kullanılan ışıınım verisi sunularak, dünya dışı radyasyon (Extraterrestrial radiation) ve bulutluluk indeksi (Clearness index) hesaplarına ait detaylar açıklanmıştır. Sonrasında, çalışmada kullanılan yöntemlere ilişkin açıklamalar sunulmuş ve önerilen hibrit yöntem anlatılmıştır.

Tez çalışmasında, Türkiye Meteoroloji Genel Müdürlüğünden temin edilen Mardin iline ait saatlik güneş ışıınım verileri kullanılmıştır. Mardin, $37,31^{\circ}$ kuzey enlemi, $40,74^{\circ}$ doğu boylamında, 1083 rakıma sahip bir konumda yer almakta olup, Türkiye geneli dikkate alındığında, iyi bir güneşlenme karakteristiğine sahiptir. Eğitim süreci için tüm veri setinin 8760 saati (2013 yılından itibaren) kullanılırken, kullanılan modellerin ve hibrit yöntemin tahmin etme yeteneğini test etmek için 8760 saat (2014 yılı) kullanılmıştır. Şekil 3.1’de Mardin iline ait kullanılan 1 yıllık güneş ışıınım verisine ait (2013) grafik gösterilmektedir.



Şekil 3.1. Mardin ili 2013 yılı saatlik güneş radyasyonu grafiği.


3.1 Extraterrestrial Radyasyon

Dünya atmosferinin tepesindeki güneş radyasyonu (veya ışıma) dünya dışı (Extraterrestrial) radyasyon olarak adlandırılır. Extraterrestrial radyasyonu hesaplamak için atmosfer üzerindeki güneş yoğunluğu ile bölgenin güneş geometrisi kullanılır. Dünya ile güneş arasındaki mesafenin yıl boyunca değişmesine neden olan dünyanın eliptik yörüngesidir ve bu dünya üzerinde belirli bir noktaya ulaşan radyasyon miktarını etkiler. Dahası, eksantrik (Eccentricity) düzeltme faktörü, dünyanın yörüngesinin eksantrikliğini hesaba katmak için kullanılır (Renné 2016, Emrah Üstündağ 2018).

Birim zaman başına güneş enerjisi miktarı, Dünya'nın Güneş'ten ortalama uzaklığında, normal bir yüzeyin birim alanında Güneş'e (radyasyonun yayılma yönüne dik) atmosferin dışına alınan güneş sabiti, I_{sc} olarak adlandırılır. Atmosferin etkisi nedeniyle bu miktarın dünya yüzeyinden ölçülmesi zordur. Sabitin belirlenmesi için bir yöntem ilk olarak 1881'de Langley (Garg 1982) tarafından önerilir ve ölçüm birimlerine dakikada Langleys (dakikada santimetre kare başına kalori) adı verilmiştir. Bu, Uluslararası Birimler Sistemi (SI: The International System of Units) tarafından metrekare başına Watt (W/m^2) olarak değiştirilmiştir.

Güneş Dünya'ya en yakın olduğunda, 3 Ocak'ta, dünya atmosferinin dış kenarındaki güneş ısısı yaklaşık $1400 W/m^2$ 'dir ve güneş en uzak olduğunda, 4 Temmuz'da, yaklaşık $1330 W/m^2$ 'dir (Kalogirou ve Soteris 2014).

Güneş sabiti (şimdi toplam gökyüzü ışıması olarak anılır) için şu anda kabul edilen değer $1366 W/m^2$ 'dir. Güneş tarafından yayılan enerji, esas olarak güneş lekeleri döngüleriyle ilişkili varyasyonlar nedeniyle yaklaşık %0,1 olduğu tahmin edilerek neredeyse değişmezdir. Bununla birlikte, dünyanın yörüngesinin eksantrikliği nedeniyle, güneş sabiti bir yıl boyunca yaklaşık %6,7 oranında değişir (Vignola vd. 2012'a).



Şekil 3.2 Güneş sabitinin zamana göre varyasyonu (Kalogirou ve Soteris 2014).

Yıl boyunca, yılın N gününde, E_{on} , yatay düzleme dik gelen dünya dışı radyasyon, Şekil 3.2'de gösterildiği gibi bu sınırlar arasında (%3,3 aralığında) değişmektedir ve (Duffie and Beckman 1991, Hsieh 1986) Eşitlik 3.1 ile hesaplanabilir:

$$E_{on} = I_{SG} \left(1 + 0.033 \cos \left(\frac{360N}{365} \right) \right) \quad (3.1)$$

N yılın günlerini belirtir. Örneğin 1 Ocak için değeri '1' 31 Aralık için değeri '365' 'e tekabül etmektedir.

E_{on} dünya dışı radyasyon, yılın N gününde (W/m^2) radyasyona normal düzlemde ölçülür.

I_{sc} güneş sabitidir (W/m^2) ve metrekaareye düşen güneş ışınım yoğunluğu olarak;

$$I_{sc} = \Omega T^4 \left(\frac{4\pi R}{4\pi D} \right)^2 = 1367 \frac{\text{W}}{\text{m}^2} \quad (3.2)$$

formülü ile açıklanır. Eşitlikte;

Ω = Stefan-Boltzman Sabiti'ni

R = Güneşin yarıçapını

D = Güneş ile Dünya arasındaki mesafeyi ifade eder.

Herhangi bir gün (n), herhangi bir saate (h) karşılık gelen extraterrestrial ışıınım değeri;

$$E_{n,h} = E_n \cdot \cos(\theta_z) \quad (3.3)$$

formülü ile hesaplanır. θ_z Zenith açısıdır ve değeri aşağıdaki formülle hesaplanır.

$$\cos(\theta_z) = \cos(\Phi) \cos(\delta) \cos(w) + \sin(\Phi) \sin(\delta) \quad (3.4)$$

Burada Φ bölgenin enlemini ifade eder. W saat açısıdır ve değeri aşağıdaki formülle hesaplanır.

$$W = \left(2\pi \frac{h-12}{24} \right) \quad (3.5)$$


Formülde h günün saatidir. Sapma açısı olarak δ ise;

$$\delta = 23,45 \cdot \sin \left(2\pi \frac{284+n}{365} \right) \quad (3.6)$$

olarak hesaplanır (Kharseh M.). Yağmur ve bulutlanma gibi atmosferik olaylar nedeniyle, güneş radyasyonunun yoğunluğu extraterrestrial radyasyonun değerinden daha düşüktür (Akarslan E. vd. 2014).

Bu tez çalışmasında, Mardin'in extraterrestrial radyasyonunu hesaplamak için şehrin enlem-boylam, zaman dilimini kullanarak, Ulusal Yenilenebilir Enerji Laboratuvarı (National Renewable Energy Laboratory) SOLPOS hesap makinesini kullanılmıştır.

Şekil 3.3'te Mardin şehri için hesaplanan extraterrestrial radyasyon verilerine ait grafik gösterilmektedir.



Şekil 3.3 Mardin ili için hesaplanan saatlik extraterrestrial radyasyon grafiği.

3.2 Bulutluluk İndeksi (Clearness index)

Atmosferik koşullardan dolayı güneş radyasyonu kaybını ölçmek için basit bir sayısal yaklaşım benimsenmiştir. Fiziksel olarak açık ve güneşli koşullar, 0 ile 1 arasında değişen bir değere sahip olan bulutluluk indeksi (K_T) olarak bilinen bir parametre ile karakterize edilir. Yüksek bir değer, açık güneşli koşullarla ilgilidir ve düşük değerler bulutlu koşulları gösterir. Bulutluluk indeksi (K_T), toplam güneş radyasyonu ile extraterrestrial radyasyon (H_o) arasındaki oran hesaplanarak elde edilir (Jahangır vd. 2019).

Aylık ortalama bulutluluk indeksi (K_T), yatay bir yüzeyde (H) ($\text{MJ/m}^2/\text{gün}$) aylık ortalama günlük radyasyonun yatay bir yüzeyde (H_o) ($\text{MJ/m}^2/\text{gün}$) aylık ortalama günlük extraterrestrial radyasyona oranıdır ve aşağıdaki formülle gösterildiği gibi hesaplanabilir (Eltamaly ve Ali 2018):

$$K_T = \frac{H}{H_o} \quad (3.7)$$

burada H (W/m^2), yatay bir yüzeyde günlük küresel güneş radyasyonunun tahmini aylık ortalamasıdır:

$$\frac{H_d}{H} = 1.39 - 4.027 \times K_T + 5.531 \times K_T^2 - 3.108 \times K_T^3 \quad (3.8)$$

H_d yatay bir yüzeyde aylık günlük ortalama dağınık radyasyon olayıdır.

H_o (W/m^2), yatay bir yüzey üzerindeki aylık ortalama dünya dışı güneş radyasyonudur ve şu şekilde hesaplanabilir:

$$H_o = \left(\frac{24}{\pi}\right) I_{SG} \times f \cdot \left[\cos \phi \cos \delta \sin W_s + \left(\frac{\pi}{180}\right) W_s \cdot \sin \delta \sin \phi \right] \quad (3.9)$$

burada f eksantriklik düzeltme faktörü, ϕ enlem, δ güneş sapması (derece) ve W_s belirli bir ay için ortalama gün doğumu saat açısıdır. Eksantriklik düzeltme faktörü, güneş sapması ve gün doğumu saat açısı aşağıdaki denklemlerde gösterildiği gibi hesaplanabilir:

$$f = 1 + 0.033 \times \cos\left(\frac{360N}{365}\right) \quad (3.10)$$

$$\delta = 23.45 \cdot \sin\left[\frac{360}{365}(284 + N)\right] \quad (3.11)$$

burada N aylık ortalama gün uzunluğu ve W_s derece cinsinden ortalama gün batımı saat açısıdır ve aşağıdaki denklemden elde edilebilir:

$$W_s = \cos^{-1}(-\tan \phi \cdot \tan \delta) \quad (3.12)$$

Tümü, her ay için verilen bir yılın gün sayısı ile tahmin edilir (Wenxian vd. 1998):


$$N = \frac{2}{15} \times W_s \quad (3.13)$$

Ancak, N 'nin aşağıdakilerden hesaplanması önerilir (Eltamaly ve Ali 2018):

$$N = \frac{2}{15} \times \cos^{-1}((\cos 85 - \sin \phi \cdot \sin \delta)/(\cos \phi \cdot \cos \delta)) \quad (3.14)$$

Bu nedenle, bulutluluk indeksi (K_T), atmosferdeki güneş radyasyonunun şeffaflık derecesinin bir göstergesidir. Stokastik bir parametredir ve yılın zamanı, mevsimi, iklim koşulları ve coğrafi konumun bir fonksiyonudur. Bu nedenle, güneş radyasyonu üzerindeki atmosferik etkileri belirlemek için güvenilir bir bulutluluk indeksi modeli gereklidir (Jahangir vd. 2019).

Şekil 3.4'te Mardin şehri için 2013 yılına ait hesaplanan bulutluluk indeksi değerlerinin değişimi görülmektedir. Gerçekleştirilen çalışmada, bulutluluk indeksi değerleri hesaplanmış ve YSA kullanılarak modellenmiştir. Oluşturulan model, ilerleyen aşamada hibrit yöntemde tercih edilecek olan modelin seçiminde kullanılacaktır.



Şekil 3.4 Mardin ili 1 yıllık bulutluluk indeksi verileri grafiği.

3.3 Yapay Sinir Ağ (YSA)

Yapay sinir ağları (YSA), insan beyninin sinir hücresi (nöron) yapısından esinlenerek geliştirilmiş, modellenen ve öğrenilebilen bir algoritmaya sahip sistemlerdir. Bu yöntem insan beyninin sinir sistemini örnek alır ve bilgisayar ortamında geliştirilir. YSA, paralel dağılmış yapısıyla doğrusal olmayan yapıları modelleyebilir ve örüntülü girdi verileriyle paralel veri işlemeye sahiptir. Dolayısıyla, en yaygın kullanılan tahmin yöntemlerinden biridir, modelleme ve kontrol konuları ile ilgili çeşitli uygulamalarda kullanılmıştır. Öte yandan, öğrenme, genelleme ve hataları tolere etme yeteneklerinden dolayı hem lineer hem de lineer olmayan sistemleri modellemede geniş uygulama alanları bulmuşlardır (Kalogirou 1999, Özçalık ve Küçüktüfekçi 2003).

Yapay Sinir Ağı, elektronik bileşenlerle tanımlanır ve bir bilgisayar tarafından simüle edilir. YSA'ların algoritmaları istatistiksele, bu nedenle hesaplamalar sayısal olarak yapılır ve tümevarımsal (endüktif) çıktılar elde edilir, ayrıca öğrenme aşamasında başarılı hesaplamalar yapmaktadır. YSA, en yüksek performans değerini elde etmek için sinir hücreleriyle güçlü bir bağlantıya sahiptir. YSA ile modellemek için, önceden girdi ve çıktı değerleri bilgisine gerek yoktur. Öğrenme, genelleme ve hata toleransı özellikleriyle öğrenme aşamasında karşılaşılmayan girdi değerlerine rağmen hesaplama yapılabilir ve bilgi işleyebilir (Abdurrahman Biçer 2017).

Yapay Sinir Ağları temelde, girdi değerlerine dayalı çıktı değerleri oluşturur. Aynı zamanda, birden fazla parametre kullanarak girdi ve çıktı değerleri arasında doğrusal olmayan bir ilişki kurarlar. Bu ilişki ile kazanılan öğrenme yeteneği, problemi en uygun şekilde çözer. YSA'lar önce, mevcut veriler kullanılarak eğitilir ve ardından eğitim sırasında kullanılmayan verilerle test edilir. YSA'ların eğitimi oldukça uzun sürse de; kullanım sırasında hızlı kararlar alma becerisine sahiptirler (Emrah Deniz ve Kemal Atik 2007).


Yapay Sinir Ağları, insan sinir hücresinin işleyişine dayalı olarak aşağıdaki maddelere dayanmaktadır (Abdurrahman Biçer 2017):

- 1- Bilgi işleme nöronlardan oluşur.

- 2- Sinyaller, nöronlar arasındaki bağlantılarla iletilir.
- 3- Nöronlar arasındaki her bağın bir ağırlık değeri vardır.
- 4- Her bir nöronun net girdisini bir aktivasyon fonksiyonundan geçirerek, her bir nöronun net projeksiyonu elde edilir (Hamzaçebi 2011b).

Bir YSA' nın temel işlem elemanı olan bir nöron aşağıda Şekil 3.5'te gösterilmiştir. Bu şekilde, m giriş sinyallerinin sayısıdır, x_i bir giriş sinyalidir ($i = 1, 2, \dots, m$ için), w_{ji} , i nöronunu j nöronuna bağlayan sinapsın gücünü temsil eden ağırlıktır ve u_j ise çıkış sinyalidir (Ahmet Koca vd. 2011). Herhangi bir YSA konfigürasyonu aşağıdaki gibi hesaplanabilir (Alam ve Teg 2019):

$$u_j = \sum_{i=1}^m w_{ji} x_i \quad (3.15)$$



Şekil 3.5 Bir nöronun şematik diyagramı (Koca vd. 2011).

Çıktı y_j aşağıdaki gibi tanımlanabilir:

$$y_j = \varphi(u_j - b_j), \quad (3.16)$$

burada $\varphi(.)$ aktivasyon fonksiyonu ve b_j eşik (threshold) değeridir. Tanjant sigmoid aktivasyon fonksiyonu şu şekilde tanımlanabilir (Picton 2000):

$$\varphi(v) = \frac{2}{1+\exp(-2v)}, \quad (3.17)$$

v aktivasyon fonksiyonunun girdisidir.

Girişler: Girişler, diğer nöronlardan gelen verileri sinir ağına getirirler.


Ağırlıklar: Girişler yoluyla alınan verilerin sinir üzerindeki etkisini belirleyen katsayılardır.

Katsayıların artırılması yapay sinir hücresine olan bağlantıyı güçlendirir.

Toplama Fonksiyonu: Girişler kendi ağırlıkları ve eşik değerleri ile çarpılarak toplanır.

Toplama işlevinin sonunda, veriler etkinleştirme işlevine gönderilir.

Aktivasyon Fonksiyonu: Yapay sinir hücresinin son aşamasıdır ve giriş ve çıkış değerleri arasında eğrisel eşleme sağlar. En yaygın etkinleştirme işlevleri logaritmik sigmoid, tanjant sigmoid ve lineer işlevleridir (Abdurrahman Biçer 2017). Bu fonksiyonların grafikleri Şekil 3.6’de gösterilmiştir.



Şekil 3.6 Aktivasyon Fonksiyonları (Doğan ve Çıngı 2010).

Logaritmik sigmoid işlevi, doğrusal ve doğrusal olmayan mutlak artışı bir işlev olarak tanımlanır. Tanjant sigmoid işlevi doğrusal olmayan ve türetilabilir bir işlevdir. Doğrusal fonksiyon, giriş değerini doğrudan çıkışa aktarır (Abdurrahman Biçer 2017).

3.3.1 Yapay Sinir Ağlarının Sınıflandırılması


Yapay sinir ağları dört farklı kategoride sınıflandırılabilir: besleme türü, öğrenme yöntemi, katman sayısı ve yapı. Besleme türüne göre, ileri ve geri beslemeli, öğrenme

yöntemi göre, öğretmenli, öğretmensiz ve destekleyici, katman sayısına göre tek katmanlı ve çok katmanlı, yapı olarak otoasosyatif ve heterososyatif olarak ikiye ayrılmaktadır (Abdurrahman Biçer 2017).

3.3.1.1 Besleme Türüne Göre Yapay Sinir Ağları

- İleri Beslemeli YSA'lar


İleri beslemeli sinir ağları, girdileri çıktılarla ilişkilendiren basit ağlardır. Sabit giriş ve çıkışlara sahiptirler. İleri beslemeli YSA'larda sinyaller girişten çıkışa tek yönde ilerler. Tek katmanlı veya çok katmanlı olabilirler. Giriş katmanına gelen veriler, giriş katmanında herhangi bir işleme tabi tutulmadan geldiği gibi orta katmandaki hücrelere geçer. Veriler bu katmanda işlenir ve çıktıya gönderilir. Şekil 3.7'de ileri beslemeli YSA'nın blok diyagramı verilmiştir.



Şekil 3.7 İleri Beslemeli YSA Blok Diyagramı (Biçer 2017).

- Geri Beslemeli YSA'lar

Geri beslemeli YSA'lar güçlüdür, sinyaller her iki yönde de hareket edebilir; nöronlar girdi olarak doğrudan bir sonraki katmana veya girdi olarak önceki katmana gönderilebilir. Gösterdikleri bu özellik nedeniyle doğrusal olmayan dinamik bir yapıya sahiptirler. Şekil 3.8'de geri beslemeli YSA'nın blok diyagramı verilmiştir.



Şekil 3.8 Geri Beslemeli YSA Blok Diyagramı (Biçer 2017).

3.3.1.2 Öğrenme Yöntemlerine Göre YSA'lar

YSA, karmaşık ve adaptif bir sistemdir, öğrenme ise en temel özelliklerindendir. YSA'da öğrenmenin önemi, belirli bir ağ oluşturulduğunda sabit aktivasyon fonksiyonunun yanı sıra giriş/çıkış vektörü nedeniyle artar. Giriş / çıkış davranışını değiştirmek için ağırlıkları ayarlamak gerekir. YSA'da öğrenme sürecinde ağırlıklar değiştirilir. Öğrenmenin amacı, yeni girişlerin hangi sınıfa atanacağını etkileyebilir (Abdurrahman Biçer 2017).

- Öğretmeli Öğrenme

Ağ eğitiminde, istenen girdi değerlerinin yanı sıra çıktı değerleriyle de tanıtıldığı bir öğrenme yöntemidir. Ağ, verilen giriş değerlerini işleyerek çıktı değerleri üretir. Bu çıktı değerlerini ağa eklenen çıktı değerleriyle karşılaştırarak bir hata değeri elde edilir. Hata değeri tolere edilebilir bir düzeye düşene kadar ağ ağırlıklarını güncelleyerek çıktıyı yeniden üretir.

- Öğretmesiz Öğrenme

Öğretmesiz öğrenmede, ağa yalnızca girdi değerleri eklenebilir. Çıkış değerleri tanımlanmaz. Girilen değerlere göre ağ, girdi değerlerini sınıflandırır, kendi kurallarını oluşturur ve ağırlıklarını belirler.

- Destekleyici Öğrenme

Destekleyici öğrenmedeki çıktı değerleri ağa tanımlanmaz. Giriş değerine karşı ağ tarafından üretilen çıktı değerinin iyi veya kötü olduğu, pozitif veya negatif olup olmadığına karar verir. Bu karara göre çıktıları belirli değer aralıklarında gruplandırır.

3.3.2 Tahmin Problemleri için Yapay Sinir Ağları

Tahmin amacıyla kullanılan YSA'larda, modellemenin sisteme uyması önemlidir. Modelleme sürecine başlamadan önce, modellemenin sisteme uyması için problemle ilgili verilere, yani girdi değerleri faktörüne dikkat edilmelidir.

Veriler, özellikle girdi değerleri, zaman serisi analizine dayalı tahminlerdeki problem serisidir. Bunlar YSA'nın girdi ve çıktı değerlerini oluşturmak için kullanılacak sıralı gözlem değerleridir. Sebep-sonuç ilişkisine dayalı tahminlerde ise girdi değerleri bağımsız değişkenler iken, çıktı değerleri bağımlı değişken verileridir. Böyle bir tahmin probleminde, modeli karmaşıklıklaştırmamak ve gereksiz değişkenler kullanarak modeli şişirmekten kaçınmak için bağımsız değişkenlerin seçilmesine özen gösterilmelidir.

YSA modelleme, verilerle ilgili işlemler tamamlandıktan sonra başlayabilir. Ağ yapısı, modelleme sürecinde ilk aşama olarak belirlenir. Yani belirlenen katman ve nöron sayısıdır. Aktivasyon fonksiyonu, YSA eğitimi, normalizasyon süreci, veri seti belirleme ve ağ performans ölçümleri sonraki aşamalardır (Abdurrahman Biçer 2017).

Bu tez çalışmasında, bayesci düzenleme geri yayılımının (*trainbr*) eğitim işlevine sahip bir YSA ağı MATLAB2016 yazılımı ile oluşturulmuş ve test edilmiştir. YSA çalışmada hem bulutluluk indeksi tahmininde hem de güneş ışınlam tahmininde kullanılmıştır.

3.4 Ekzojen Girdili Doğrusal Olmayan Otoregresif Modeller (NARX)


NARX modeli, “ekzojen girdili doğrusal olmayan otoregresif modellerin” kısaltmasıdır. Tekrarlayan dinamik sinir ağları altında kayıtlıdır. Ekzojen girdilere sahip doğrusal olmayan otoregresif bir modeldir. NARX, biri giriş ve diğeri çıkış için olmak üzere iki

gecikmeli doğrusal ARX modelinden oluşur. Çok katmanlı algılayıcıya ve yinelenen bağlantılara dayanır. Bu model zaman serileri, tahminin yanı sıra doğrusal olmayan dinamik sistem modellemesi için de kullanılır. Diğer sinir ağı türleriyle karşılaştırıldığında, NARX modeli iyi öğrenme, hızlı yakınsama ve daha iyi genelleme karakteristiğine sahiptir. NARX modelinin performansı, nöronlar için girdi olarak uygulanan çeşitli kaotik veya fraktal zaman serileri için doğrulanır (Diaconescu 2008). Dinamik sistemleri modellemeye çok uygun olduğu için, önerilen tez çalışmasında da kullanılmak üzere seçilmiştir. NARX modelinin matematiksel formülasyonu aşağıdaki gibi tanımlanır:

$$y(t) = f(y(t-1), \dots, y(t-n_y); u(t), \dots, u(t-n_u)) + \varepsilon(t), \quad (3.18)$$

burada $y(t)$ ve $u(t)$, ayrı bir zaman adımında modelin geçmiş ve şimdiki bağımsız (ekzojen) girişleridir t , $n_y \geq 1$, $n_u \geq 1$, $n_y \geq n_u$, giriş belleği ve çıkış bellek sıralarıdır (gecikme) ve f doğrusal olmayan bir eşleme işlevidir (Di Piazza vd. 2016).

f fonksiyonu çok katmanlı bir algılayıcı (MLP: Multilayer Perceptron) tarafından yaklaşık olarak alındığında, ortaya çıkan sinir ağı NARX ağı olarak adlandırılır. Başka bir deyişle, bir NARX ağı, girdi olarak geçmiş bağımsız (ekzojen) girdilerin ve geçmiş çıktıların bir penceresini alan ve mevcut çıktıyı hesaplayan bir MLP'den oluşur. Geleneksel bir tekrarlayan sinir ağından farklı olarak, NARX ağı, gizli durumlardan ziyade yalnızca çıkış nöronu tarafından gelen sınırlı bir geri bildirime sahiptir. Doğrusu, yalnızca NARX'in çıkışı, ileri beslemeli sinir ağının girişine geri beslenir. Bununla birlikte, tamamen bağlı bir tekrarlayan sinir ağı kadar hesaplama açısından güçlü olduğu gösterilmiştir (Di Piazza vd. 2016). Aşağıda Resim 3.1'de, NARX modelinin konfigürasyonu gösterilmektedir.



Resim 3.1 NARX tekrarlayan sinir ağı mimarisi (Massaoudi vd. 2019).

Standart NARX ağı, gizli katmanda sigmoid transfer fonksiyonu ve çıktı katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı bir ileri besleme ağına sahiptir. Bu ağ, $x(t)$ ve $y(t)$ dizilerinin önceki değerlerini saklamak için bir kademe geciktirme hatları içeren belirli bir özelliğe sahiptir. Dikkat edilirse, NARX ağının çıkışı $y(t)$, ağın girişine geri beslenir (gecikmeler yoluyla). Bu güçlü dinamik model sınıfını eğitmek için iki farklı modu ortaya çıkarır (Mohamed Massaoudi vd. 2019):

Seri Paralel (SP) modu: Gözetim altında eğitim için kullanılan veri tabanında verilen gerçek değerlerden gecikmeli geribildirim bilgileri alır:

$$\hat{y}(n+1) = \hat{f}[y_{sp}(n); u(n)] = \hat{f}[y(n), \dots, y(n-d_{y+1}); u(n), \dots, u(n-d_y+1)] \quad (3.19)$$

Paralel (P) modu: çıktının regresörü için tahmini çıktıların ayarlandığı yer:

$$\hat{y}(n+1) = \hat{f}[y_p(n); u(n)] = \hat{f}[y(n), \dots, y(n-d_{y+1}); u(n), \dots, u(n-d_y+1)] \quad (3.20)$$

Bununla birlikte, daha iyi doğruluk ve etkili eğitim için, yukarıda YSA modeliyle kullanılan aynı verilerle açık döngüde NARX-SP geri bildirimi bu tez çalışmasında kullanılmıştır ve tasarlanan sisteme ait ayrıntılar bir sonraki bölümde açıklanacaktır.

3.5 Ridge Regresyon

Ridge regresyon, çok lineerlikler yaşayan çoklu regresyon verilerini analiz etmek için kullanılan bir tekniktir. Çok lineerlik oluştuğunda, en küçük kareler tahminleri tarafsızdır, ancak varyansları büyüktür, bu nedenle gerçek değerden uzak olabilirler. Regresyon tahminlerine bir derece önyargı ekleyerek, ridge regresyon standart hataları azaltır. Net etkinin daha güvenilir tahminler vermesi umulmaktadır. Başka bir önyargılı regresyon tekniği, ana bileşenler regresyonu, NCSS' de (Sosyal Bilimler Ulusal Konseyi) de mevcuttur (Gariballa Abdelmageed ve Hussein Eledum 2016). Ridge regresyonu, iki yöntemden daha popüler olanıdır. Ridge regresyon, çoklu regresyon modellerinin katsayılarını tahmin etmenin bir yöntemi olduğu için, çoklu doğrusal regresyon standart modeli aşağıdaki gibidir:

$$y = X\beta + \varepsilon \quad (3.21)$$

y 'nin bağımlı değişkeni $n \times 1$,

X bağımsız değişkenleri $n \times p + 1$,

β bilinmeyen parametrelerin $p \times 1$,

ε ise $n \times 1$ 'lik artıkların matrisini oluşturmaktadır.

Çoklu doğrusal regresyon için standart modeli $y = X\beta + \varepsilon$ olduğu kabul edilir; burada X 'in $(n \times p)$ olduğu ve p ranklı β 'nin $(p \times 1)$, ve $(E[\varepsilon] = 0$ ve $E[\varepsilon \varepsilon'] = \sigma^2 I_n)$ olduğu varsayılır. Burada I_n , n boyutlu kimlik matrisini temsil eder. Faktörlerle ilgili bir gözlem $X_v = \{x_{1v}, x_{2v}, \dots, x_{pv}\}$, $X\beta$ genel biçimi $\{\sum_{i=1}^p \beta_i \theta_i(X_v)\}$ olur ve burada θ , bilinmeyen parametreler içermeyen fonksiyonlardır.

Bilinmeyen β için olağan tahmin prosedürü, tarafsız olan ve minimum varyansa sahip olan $Y = \{y_p\}$ 'nin Gauss-Markov-lineer fonksiyonlarıdır. $X'X$, bir korelasyon matrisi biçimindeyken, neredeyse bir birim matris ise, bu tahmin prosedürü iyi bir yöntemdir.

Bununla birlikte, $X'X$ neredeyse bir birim matris değilse, en küçük kareler tahminleri bir dizi "hataya" duyarlıdır. Bu hataların sonuçları, $X\beta$ 'in gerçek bir model olduğu belirtildiğinde çok önemlidir.

Sıradan en küçük karelerde, regresyon katsayıları aşağıdaki formül kullanılarak tahmin edilir (E. Hoerl and Robert W. Kennard 1970):

$$\hat{\beta} = (X'X)^{-1}X'y \quad (3.22)$$

β 'nin tahmini olarak, buradaki, kalıntıların karelerinin minimum toplamını aşağıdaki gibi verir:

$$\phi(\hat{\beta}) = (Y - X\hat{\beta})'(Y - X\hat{\beta}) \quad (3.23)$$

A. E. Hoerl ilk olarak 1962'de (HOERL 1962, HOERL and KENNARD 1968) en küçük kareler tahminleriyle ilişkili enflasyonu ve genel istikrarsızlığı kontrol etmek için şunların kullanılabileceğini önermiştir:

$$\hat{\beta}^* = [X'X + kI]^{-1}X'Y; k \geq 0 \quad (3.24)$$

$$= WX'Y \quad (3.25)$$

$k \geq 0$ ile verilen tahminler ailesi, ikinci dereceden tepki fonksiyonlarının tasviri ile birçok matematiksel benzerliğe sahiptir (HOERL 1964). Bu nedenle (3.24) etrafında oluşturulan tahmin ve analiz, "Ridge regresyonu" olarak adlandırılmıştır. Bir ridge tahmininin sıradan bir tahminle ilişkisi, alternatif biçimde verilmiştir:

$$\hat{\beta}^* = [I_p K(X'X)^{-1}]^{-1}\hat{\beta} \quad (3.26)$$

$$= Z\hat{\beta} \quad (3.27)$$

Bu ilişki, Hoerl ve Robert Kennard (1970) tarafından daha fazla araştırılmıştır. Kullanılan $\hat{\beta}^*$, W ve Z 'nin bazı özellikleri şunlardır:

$\xi_i(W)$ ve $\xi_i(Z)$, sırasıyla W ve Z 'nin özdeğerleri olsun. Bu durumda aşağıdaki eşitlikler elde edilir;

$$\xi_i(W) = 1/(\lambda_i + k) \quad (3.28)$$

$$\xi_i(Z) = 1/(\lambda_i + k) \quad (3.29)$$

burada λ_i , $X'X$ 'in özdeğerleridir. Bu sonuçlar doğrudan (3.25) ve (3.27) ' deki W ve Z tanımlarından ve $|W - \xi I| = 0$ ve $|Z - \xi I| = 0$ karakteristik denklemlerinin çözümünden gelir.

$$Z = I - k(X'X + kI)^{-1} = I - kW \quad (3.30)$$

İlişki, $Z = (X'X + kI)^{-1}X'X = WX'X$ alternatif biçiminde Z yazılarak ve eşitlik (3.30)'un her iki tarafının W^{-1} ile çarpılmasıyla kolayca doğrulanır.

$k \neq 0$ için $\hat{\beta}^*$, $\hat{\beta}$ 'den daha kısadır, yani

$$(\hat{\beta}^*)'(\hat{\beta}^*) < \hat{\beta}'\hat{\beta}. \quad (3.31)$$

$\hat{\beta}^* = Z\hat{\beta}$ denkleminin tanımına göre; Bu tanıma ve $X'X$ ile ilgili varsayımlara göre, Z 'nin simetrik pozitif tanımlı olduğu açıktır. Bu durumda, bağıntı aşağıdaki gibidir (RILEY 1955):

$$(\hat{\beta})'(\hat{\beta}) \leq \xi_{max}^2(Z) \hat{\beta}'\hat{\beta}. \quad (3.32)$$

Ancak denklem $\xi_{max}(Z) = \lambda_i/(\lambda_i + k)$, burada λ_i , $X'X$ 'in en büyük özdeğeridir ve denklem (3.31) kurulur. (3.29) ve (3.30) denklemlerinden, $Z(0) = I$ olduğunu ve $k \rightarrow \infty$ olduğunda Z 'nin 0 eğiliminde olduğunu görülmektedir.

Bir $\hat{\beta}^*$ tahmini için artık kareler toplamı aşağıdaki gibidir:

$$\phi^*(k) = (Y - X\hat{\beta}^*)'(Y - X\hat{\beta}^*) \quad (3.33)$$

$$\phi^*(k) = Y'Y - (\hat{\beta}^*)'X'Y - k(\hat{\beta}^*)'(\hat{\beta}^*) \quad (3.34)$$


Denklemin ifadesi şunu gösterir; $\phi^*(k)$ 'nin, $\hat{\beta}^*$ 'nin kare uzunluğuna bağlı bir değişiklik, $\hat{\beta}^*$ için karelerin "regresyon" toplamının çıkarılmasıyla elde edilen kareler toplamıdır.

3.6 Hibrit Metot

Bu bölümde, saatlik güneş ışınımını tahmin etmek için yeni bir hibrit metot önerilmiştir. Önerilen hibrit metot, üç etkili yöntemin birleşimidir. Bu füzyon, bireysel yöntemlerden daha iyi performans gösterebilen sağlam bir model sunar (Al-Enezi vd. 2010). Hibrit yöntem oluşturmak için Ridge Regresyon, NARX ve YSA ağlarının yöntemlerini seçmenin temel amacı şu şekilde özetlenebilir; Dinamik sinir ağının tahmin konularındaki performansı ve NARX modellerinin avantajları göz önüne alındığında, bu araştırmada NARX bir tahmin tekniği olarak ele alınmıştır (Boussaada 2017). Ridge regresyon, model karmaşıklığını azaltmanın ve doğrusal regresyondan kaynaklanabilecek aşırı uyumu önlemenin farklı bir yoludur (İbrahim vd. 2012). Ayrıca, Yapay sinir ağı modeli (YSA), geleneksel regresyon tabanlı ampirik modellemeye göre daha fazla gürültü toleransına sahip olmakla birlikte, aynı zamanda tamamlanmamış ve bozulmuş verilerle karmaşık sistemleri öğrenme yeteneğine sahiptir. Bu özelliklerle, her modelin özelliği aktarıldığından doğruluğu artmaktadır. Bu nedenle, tahmin durumunda, hibrit yöntemler, daha güçlü bir tahmin edici oluşturmak için bireysel yöntemlerin özelliklerini birleştirir (Hani Omar vd. 2016).

Fazla uydurmayı (overfitting) önlemek için sistematik bir yaklaşım, verileri üç alt kümeye bölmektir: (1) Öğrenme, (2) Validasyon ve (3) Test alt kümeleri. Test veri setleri, modellerin öğrenmedikleri veriler üzerinde genelleme yeteneğini belirtmek için kullanılmıştır (model seçimi). Öğrenme ve doğrulama verileri modelleme sürecine dahil

edilmiştir ve “eğitim verileri” olarak adlandırılan bir gruba ayrılmıştır. Hem öğrenme hem de doğrulama veri setlerinde en iyi performansa sahip modeller, son olarak çalışmanın sonuçları olarak seçilmiştir. Test verileri, modellerin oluşturulmasında rol oynamayan veriler üzerindeki son modellerin performansını ölçmek için kullanılmıştır. Son olarak, Hibrit yöntemin geliştirilmesi sırasında, eğitim verilerinin clearness index değerine bağlı olarak 3 farklı tahmin modeline ayrılmış, burada öncelikli güneş radyasyonu verileri her üç yöntem kullanılarak modellenmiş ve her bir clearness index bandı arasındaki ilişkiler incelenmiştir. Son olarak, bir hibrit yöntem oluşturmak için üç model arasından başarılı modeller seçilmiştir. Yöntem ve sonuçlar sonraki bölümlerde daha fazla açıklanacaktır. Hibrit yöntemin ayrıntılarını gösteren bir prensip şeması Şekil 3.9’da gösterilmektedir.



Şekil 3.9 Hibrit Yöntemin Prensip Şeması

Hibrit metodun oluşturulmasında kullanılan temel mantık, aşağıdaki pseudo kodda ifade edilmiştir:

Çizelge 3.1 Hibrit Yöntem Algoritması için Pseudo Kodu.


Hibrit Metot Algoritması
<pre> % Clearnessindexi YSA ile tahmin et for i = 1:m % burada 'm', veri sayısıdır. if clearnessindex(i) < 0.35 Tahmin(i) = YSA(i) elseif clearnessindex(i) > 0.35 & clearnessindex(i) < 0.70 Tahmin(i) = YSA(i) else Tahmin(i) = NARX(i) </pre>

4. DENEYSEL ÇALIŞMA

Gerçekleştirilen çalışmada Mardin ili güneş ışınlam tahmini için hibrit bir yöntem geliştirilmiştir. Hibrit yöntem içerisinde kullanılması planlanan yöntemler Yapay Sinir Ağları, Ridge Resresyon ve NARX olarak belirlenmiş ve ilk olarak veri seti bu yöntemler kullanılarak modellenmiştir. Sonra belirlenen stratejiye uygun olarak hibrit yöntem ile modelleme gerçekleştirilmiş, sonuçlar değerlendirilerek, yorumlanmıştır. Bu kapsamda tüm model ve analizler, MATLAB yazılımı kullanılarak gerçekleştirilmiştir.


4.1 Veri Setlerinin Oluşturulması

Mardin ili 2013-2014 yıllarına ait güneş ışınlam verileri Türkiye Meteoroloji İşleri Genel Müdürlüğünden alınmış ve düzenlenmiştir. Mevcut veriler 2013 yılı Ocak ayı başından 2014 yılı Aralık ayı sonuna kadar olan verilerdir. Saatlik değerlerin mevcut olduğu düşünüldüğünde, 17520 adet veri bulunmaktadır. Bu verilerin 8760 adedi oluşturulan modellerin eğitimi için, geri kalanı ise test verisi olarak kullanılmıştır. Şekil 4.1, Mardin iline ait eğitimde kullanılan 1 yıllık (2013) güneş radyasyonu verilerinin grafiğini göstermektedir.



Şekil 4.1. Mardin ili 2013 yılı saatlik güneş radyasyonu grafiği.

Daha sonra, Mardin iline ait extraterrestrial radyasyonunu hesaplamak için şehrin enlem-boylam, zaman dilimini kullanarak, Ulusal Yenilenebilir Enerji Laboratuvarı (National Renewable Energy Laboratory) SOLPOS hesap makinesi kullanılmıştır. Extraterrestrial radyasyon, Dünya'nın eliptik yörüngesi nedeniyle yıl boyunca değişir, bu da Dünya-Güneş mesafesinin yıl boyunca tahmin edilebilir bir şekilde değişmesine neden olur. Şekil 4.2, Mardin ili için kullanılan 1 yıllık (2013) saatlik extraterrestrial radyasyon grafiğini göstermektedir.



Şekil 4.2. Mardin ili için hesaplanan saatlik extraterrestrial radyasyon grafiği.

4.2 Değerlendirme Metrikleri

Çalışmada kullanılan yöntemlerin performansı, Ortalama Kare Hata (MSE) ve Kök Ortalama Kare Hata (RMSE) genel istatistikler kullanılarak değerlendirilmiştir. Performans değerlendirme işlevleri, gerçek ve tahmin edilen çıktı veri kümeleri arasındaki varyasyonu test ederek ağ eğitiminin doğruluğunu test etmek için kullanılan istatistiksel araçlardır. İstatistikte MSE, gerçek ve tahmini değerler arasındaki farkın karesinin ortalaması olarak tanımlanır. MSE, tahminlerin gerçek değerlere ne kadar yakın olduğunu kontrol etmek için kullanılır. Bu, regresyon modelleri için bir model değerlendirme ölçüsü olarak kullanılır ve düşük değer daha iyi bir uyumu gösterir. Ayrıca, burada RMSE, tüm hatanın karesinin ortalamasının karekökü olur. RMSE

kullanımı çok yaygındır ve sayısal tahminler için mükemmel bir genel amaçlı hata ölçütü olarak kabul edilir.

Bu çalışmada hibrit, YSA, NARX ve Ridge regresyon modellerinin performansını değerlendirmek için kullanılan doğruluk ölçütleri Çizelge 4.1'de listelenmiştir:

Çizelge 4.1 Sinir Ağı Performans İşlevleri.

Fonksiyon	İsim	Algoritma
MSE	Ortalama Kare Hata	$\frac{1}{n} \sum_{i=1}^n (y_a(i) - y_p(i))^2$
RMSE	Kök OrtalamaKare Hata	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_a(i) - y_p(i))^2}$

Burada y_a gözlem çıktısı, y_p bir değişkenin tahmini değerleri ve n analiz için mevcut gözlem sayısıdır.

4.3 Güneş Işınımının Modellenmesi

Bu araştırmada, güneş radyasyonu verileri YSA, NARX ve RR ile eğitilmiş ve modellenmiştir. Burada girdi olarak 3 veri (1 saat önceki güneş radyasyonu, 2 saat önceki güneş radyasyonu ve extraterrestrial değeri) ve çıktı olarak güneş radyasyonunun mevcut değeri kullanılmıştır. Son olarak, test verileri kullanılarak eğitilen modeller test edilmiştir.

Yöntemlerin (YSA, NARX ve RR) oluşturulabilmesi ve eğitilebilmesi için veri tabanındaki giriş ve çıkış değerlerinin MATLAB'a aktarılması gerekmektedir. Tüm veriler önce 8760x3 matris olarak MATLAB'A aktarılır. Daha sonra, yöntemlerin eğitimi için girdi ve çıktı matrislerinin ayrılması gerekir. Giriş matrisi 8758x3 matrisine ve çıkış matrisi 8758x1 matrisine atanır. YSA'lar sütunlarla ve NARX satırlarla işlem yaptığından, bu matrisler YSA ve NARX uygun olması için transpozese alınır. Aşağıda kullanılan yöntemler (YSA, NARX ve RR) detaylı olarak anlatılacak ve elde ettiğimiz sonuçlar sunulacaktır.

- YSA'nın Oluşturulması

Çalışmada farklı YSA modelleri oluşturulmuş ve bu YSA modelleri arasında doğruluk oranı en yüksek olan ağa ulaşılmaya çalışılmıştır. Katmanlardaki farklı sayıda nöron, eğitim için optimizasyon algoritmaları ve yineleme sayısı ile test edilerek en yüksek doğruluğa sahip ağ seçilmiştir.

YSA ağının girdisi (güneş ışıınımı 1 saat önceki, güneş ışıınımı 2 saat önceki, extraterrestrial mevcut değeri) ve çıktısı (güneş ışıınımının mevcut değeri) olarak 2013 yılı için daha önce elde edilen 8760 örneğe sahip ölçülmüş veriler kullanılmıştır. Bu veriler arasında eğitim için ayrılan verilerin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır. Gizli katmandaki nöron sayısı deneme yanılma tekniği uygulanarak 40 olarak seçilmiştir. Oluşturulan ileri beslemeli ağın eğitimi için MATLAB bünyesinde bulunan Bayesian regülasyon geri yayılma optimizasyon algoritması ile geliştirilen “trainbr” eğitim fonksiyonu kullanılmıştır. Oluşturulan ağın parametrelerinin belirlenmesi Şekil 4.3'te gösterilmektedir.

```
trainFcn = 'trainbr'; % Ağın Eğitim Fonksiyonu%Yapay sinir Ağının Nöron
sayısı
net = fitnet (hiddenLayerSize,trainFcn); % Ağın Besleme Tipi, İleri Beslemeli
net.trainParam.epochs = 5000; % Ağın Kaç İterasyonda Biteceği
net.trainParam.show = 1000; % Eğitim Aşamasında Ağın Yakaladığı Hata
Değerini Kaç iterasyonda Bir Ekranda Gösterdiği
net.trainParam.goal= 0.000001; % Ağda Hedeflenen Hata Değeri. Bu Hata Değeri
Yakalanınca Eğitim Biter
net.trainParam.max_fail = 100; % Ağın Yakaladığı Hata Değerini Kaç
iterasyonda Tekrarlarsa Eğitim Bitirileceği
net.PerformFcn = 'mse'; % Ağın Eğitim Performansının Belirleneceği Parametre.
Hata Oranlarının Kareleri
net.divideParam.trainRatio = 70/100; %Veri Setindeki Değerlerin Yüzde 70'i
Eğitimi
net.divideParam.valRatio = 15/100; % Değerlerin Yüzde 15'i Doğrulama İçin
net.divideParam.testRatio = 15/100; % Değerlerin Yüzde 15'i Test İçin
kullanılmıştır.
```


Şekil 4.3 YSA Ağının Oluşturulduğu Parametreler.

2013 yılı için Mardin'de saatlik güneş radyasyonu tahmini için YSA modelinin performansının sonuçlarının bir özeti Çizelge 4.2'de gösterilmektedir.

Çizelge 4.2 YSA Ağı'nın sonuçları.


YSA	Değerlendirme Parametleri	
	MSE	RMSE
Eğitim	3157.0801	56.1879
Test	3476.2816	58.9630

Son olarak, saatlik güneş radyasyonunu tahmin etmek için üç girişli, bir gizli katmanda 40 nöron ve bir çıkış birimi olan bir sinir ağı eğitilmiştir ve test edilmiştir. 2013 yılına ait veriler eğitim için kullanılırken, 2014 yılına ait verilerin tamamı test için kullanılmıştır. Bu durum için RMSE, eğitim verilerinde 56.18 iken, test verilerinde 58.96 olarak belirlenmiştir. Oluşturulan ağı yapısı Şekil 4.4'te gösterilmiştir.




Şekil 4.4 Oluşturulan YSA'nın Yapısı.

Şekil 4.5 ağı eğitim aşamasında elde edilen metrikleri göstermektedir. Oluşturulan ağı yapısı, kullanılan algoritma, hata performans yöntemi, eğitimin performans grafiği ve sistemin uygunluk düzeyini belirlemek için oluşturulan regresyon doğrularına bu sekmeden ulaşılabilir. Şekil 4.6'te oluşturulan ağı performans grafiği gösterilmektedir. Ağı hata hedefi 10^{-4} olarak belirlenmişken, oluşturulan YSA yaklaşık olarak 10^4 değerine yaklaşmıştır.




Şekil 4.5 Oluşturulan YSA'nın Eğitim Aşaması.




Şekil 4.6 Oluşturulan Ağın Eğitim Performansı.

Şekil 4.7'de ağın regresyon doğruları gösterilmektedir. Sistemin uygunluğu regresyon doğruları ile belirlenir. Regresyon doğrularını oluşturan parametre, tahmin edilen değerlerin gerçek değerlere oranı ile hesaplanır (Koutsoyiannis 1989). Regresyon değeri 0 ile 1 arasında bir değer alır. Verinin 0 olması sistemin uyumsuz olduğunu ve 1 olması ise sistemin uyumlu olduğunu gösterir. Bu nedenle regresyon katsayısının 1'e oldukça yakın olması istenmektedir. Uyumun yeterli sayılabilmesi için, regresyon değerinin 0,9 ile 1 aralığında olması gerekmektedir. Uygulamamızda bu değer ortalama 0,98 olarak hesaplanmıştır. Şekil 4.8, test verileri için tahmini saatlik güneş radyasyonunun grafiğini göstermektedir.



Şekil 4.7 Oluşturulan Ağın Regresyon Doğruları.



Şekil 4.8 YSA testinin grafiği.

- NARX Modelinin Oluşturulması

NARX modellerinin tasarlanması, bir dizi sistematik prosedürün takip edilmesini gerektirir. Oluşturulan ağın parametrelerinin belirlenmesi Şekil 4.7'de gösterilmiştir. Bu çalışmada NARX ile tahminde takip edilen beş temel adım şunlardır:

i. Verilerin ön işlenmesi: Bu, eksik verilerin sıralanmasını ve kübik spline enterpolasyonu kullanılarak düzleştirilmesini ve korelasyon analizi kullanılarak input/target değişkenlerin belirlenmesini içerir (Kiusalaas 2010).

ii. Ağ oluşturma: Ağ oluştururken, uygun bir ağ oluşturmak için gereken bazı temel parametreler belirtilir. Bunlar şunları içerir: ağ adı, gizli katman sayısı, her katmandaki nöronlar, zaman gecikmesi satırlarının sayısı, eğitim fonksiyonu, ağırlık ve önyargı öğrenme fonksiyonu, veri bölme fonksiyonu ve performans fonksiyonu. Oluşturulan *narxnet*'in iki girişi vardır: $x(t)$ harici girişi ve $y(t)$ ağ çıkışından gelen geri besleme bağlantısı. Bu girişlerin her biri, önceki değerleri depolamak için kademeli bir gecikme hattına sahiptir. Bu çalışmada giriş ve çıkış katmanlarına ek olarak iki gizli katman kullanılmıştır.

iii. Verilerin eğitim için hazırlanması: Gecikme hatları ile ağın eğitiminde, gecikmeleri ağın giriş ve çıkışlarının başlangıç değerleriyle doldurmak önemlidir. MATLAB'da bu işlemi kolaylaştırmak için hazırlıklar fonksiyonu '*preparets*' kullanılmıştır. *Preparets*'in üç giriş argümanı vardır: ağ, giriş serileri ve hedef serileri. Fonksiyon MATLAB'da şu şekilde uygulanmıştır:

$$[inputs, inputStates, layerStates, targets] = preparets(net, inputSeries, \{\}, targetseries) \quad (4.1)$$

iv. Ağı eğitmek: sinir ağı başarıyla eğitilmiş ve ağırlıklar kaydedilmiştir. Eğitim sürecinde, üretilen tahmini çıktıya kadar sistematik olarak ayarlanan ağırlıklar daha az değer hatası verir. Bu düzeltici ayarlamalar, eğitim verileri en iyi hatayı elde edene kadar devam etmiştir.

v. Model performansının test edilmesi ve doğrulanması: bu araştırmada, NARX modelin performansının test edilmesi ve doğrulanması için MSE ve RMSE kriterleri kullanılmıştır.

```

X = tonndata(input,false,false); % giriş - giriş zaman serisi.
T = tonndata(output,false,false); % çıktı - geri besleme zaman serisi.
% Bir Eğitim İşlevi Seçin
% Tüm eğitim işlevlerinin listesi için: help nntrain
trainFcn = 'trainbr'; % Bayesian Regulation backpropagation
% Açık Döngü Ağı
% Harici Girdi ile Doğrusal Olmayan Otoregresif Ağ Oluşturun
inputDelays = 0;
feedbackDelays = 1:1;
hiddenLayerSize = 40;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);
[x,xi,ai,t] = preparets(net,X,{},T);
% Eğitim, Doğrulama, Test için Veri Bölümünün Kurulumu
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
[net,tr] = train(net,x,t,xi,ai); % Ağı Eğit
% Ağı Test Et
y = net2(x,xi,ai); % 2013 yılı verilerinin simülasyonu
e = gsubtract(t,y);
performance = perform(net,t,y);

```

Şekil 4.9 NARX Ağının Oluşturulduğu Parametreler.


NARX modelinin 2013 yılı Mardin'de saatlik güneş radyasyonu tahmini performansının sonuçlarının bir özeti Çizelge 4.3'te gösterilmektedir.

Çizelge 4.3 NARX'ın sonuçları.

NARX	Değerlendirme Parametreleri	
	MSE	RMSE
Eğitim	3468.3736	58.8929
Test	4577.9161	67.6603


Üç girişli, bir katmanda 40 gizli nöron ve bir çıkış birimi olan NARX ağı, saatlik güneş radyasyonunu tahmin etmek için eğitilmiştir. 2013 yılı verileri eğitim ve 2014 yılı verileri test için kullanılırken, eğitim verilerinde RMSE değeri 58.89 olarak hesaplanırken, test verilerinde 67.66 olarak belirlenmiştir.

NARX ağının girdisi (Güneş ışınlımı 1 saat önceki, Güneş ışınlımı 2 saat önceki, extraterrestrial mevcut değeri) ve çıktısı (güneş ışınlımının mevcut değeri) olarak 2013 yılı için daha önce elde edilen 8760 veri kullanılmıştır. Bu verilerin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır. Gizli katman nöron sayısı deneme yanılma tekniği uygulanarak 40 olarak seçilmiştir. Oluşturulan ileri beslemeli ağın eğitimi için MATLAB bünyesinde bulunan Bayesian regülasyon geri yayılma optimizasyon algoritması ile geliştirilen “trainbr” eğitim fonksiyonu kullanılmıştır. Oluşturulan ağın yapısı Şekil 4.10’de gösterilmiştir.




Şekil 4.10 Oluşturulan NARX’ın Yapısı.


Aşağıdaki Şekil 4.11 ağın eğitim aşamasını göstermektedir. Oluşturulan ağın yapısı, kullanılan algoritma, hata performans yöntemi, eğitimin performans grafiği ve sistemin uygunluk düzeyini belirlemek için oluşturulan regresyon doğrularına bu sekmeden ulaşılabilir. Şekil 4.12’de oluşturulan ağın performans grafiği gösterilmektedir. Ağın hata hedefi 10^{-4} olarak belirlenmişken, oluşturulan NARX yaklaşık olarak 10^4 değerine yaklaşmıştır. Şekil 4.13, Mardin’in 2013 yılında saatlik güneş ışınlımı kullanılarak eğitilen NARX ağının performans değerlendirmesinin regresyon grafiklerini göstermektedir.



Şekil 4.11 Oluşturulan NARX'in Eğitim Aşaması.




Şekil 4.12 Oluşturulan Ağın Eğitim Performansı.



Şekil 4.13 Oluşturulan Ağın Regresyon Doğruları.

Şekil 4.14, test verileri için tahmini saatlik güneş radyasyonunun grafiğini göstermektedir.



Şekil 4.14 NARX testinin grafiği.

- Ridge Regresyonunun Oluşturulması


Bu araştırmada, güneş radyasyonunu tahmin etmek için kullanılan bir diğer yöntem Ridge regresyon yöntemidir. Burada “*cvpartition*” komutu, çapraz doğrulama için, yani eğitim ve test verilerini her aşamada değiştirmek için kullanılmıştır. Ayrıca Ridge regresyonunun parametrelerinde, “*cvpartition*” komutu ile bulunan Ridge regresyonu tarafından eklenen bir ridge parametresi (k) kullanılmıştır. Ridge parametresi (k) sıfır olmamalıdır. O halde (k) küçük seçilmeli ama sıfır olmamalıdır, burada k 'nin değeri $k=5$ olarak seçilmiştir. Aşağıdaki Şekil 4.15 Ridge Regresyon Parametrelerini göstermektedir.

```

%%% Ridge Regresyonunun katsayıları
% Güneş radyasyonu veri setini yükleyin. Verileri eğitim ve test kümelerine
ayırın.
X = input;
y = output;
% Verileri eğitim ve test kümelerine ayırın
n = length(y);
rng('default') % Tekrarlanabilirlik için
c = cvpartition (n,'HoldOut',0.99);
idxTrain = training(c,1);
idxTest = ~idxTrain;
% Ridge regresyon modelinin katsayılarını bulun (k = 5 ile).
k = 5;
b = ridge (y(idxTrain), X(idxTrain,:), k,0);
% Modeli kullanarak test verileri için çıktı değerlerini tahmin edin.
yhat= b(1) + X (idxTest,:)*b(2:end);

```

Şekil 4.15 Ridge Regresyon Parametreleri.



Şekil 4.16 Ridge Regresyon testinin grafiği.

Şekil 4.16, test verileri için tahmini saatlik güneş radyasyonunun grafiğini göstermektedir.

Ridge Regresyon modelinin 2013 yılı Mardin’de saatlik güneş radyasyonu tahmini performansının sonuçlarının bir özeti Çizelge 4.4’te gösterilmektedir.

Çizelge 4.4 Ridge Regresyon sonuçları.

Ridge Regresyon	Değerlendirme Parametreleri	
	MSE	RMSE
Eğitim	7372.0254	85.8605
Test	14356.3531	119.8180

Ridge Regresyon parametreleri, katsayısı ile saatlik güneş radyasyonunu tahmin etmek için eğitilmiştir ve test edilmiştir. 2013 yılına ait veriler eğitim, 2014 yılına ait veriler ise test için kullanılmıştır. Bu durum için RMSE, eğitim verilerinde 85.86 iken, test verilerinde 119.81 olarak hesaplanmıştır. Eğitim ve test verileri için elde edilen hata değerleri arasında büyük bir fark olduğu görülmektedir. Bunun sebebinin iki yıl arasında güneş ışıınım değişiminde büyük bir farktan kaynaklandığı düşünülmektedir. Ridge regresyon yönteminin doğrusal bir yöntem olduğu düşünüldüğünde, bu fark anlaşılabilir.

4.4 Clearness Index'in Modellenmesi

Oluşturulan hibrit yöntemde clearness index değerine bağlı bir karar mekanizması bulunduğu için, öncelikle clearness index'i hesaplamak gerekir. Clearness index değeri herhangi bir an için güneş ışıınım değerinin extraterrestrial ışıınım değerine oranıdır. Ancak extraterrestrial ışıınım değerleri içerisinde sıfırlar (güneşin olmadığı saatler) mevcuttur ve bu clearness index hesabında probleme sebep olur. Extraterrestrial'in sıfır olduğu durumda bir bulutluluk durumundan bahsedilemeyeceği için, bu durumda clearness indexin de sıfır olması gerekir. Bu nedenle extraterrestrial ışıınımın sıfır olduğu yerlerde clearness index değerine sıfır atanmış, diğer durumlarda ölçülen ışıınım değeri extraterrestrial radyasyon değerine bölünerek clearness index değeri hesaplanmıştır. Ardından, 2013 yılı eğitim verilerinin clearness index değeri hesaplandıktan sonra, clearness index verileri YSA tarafından eğitilmiş ve 2014 yılı test verileri kullanılarak test edilmiştir. Sonuçlar Çizelge 4.5'te aşağıdaki gibi gösterilmektedir.

Çizelge 4.5 Clearness index sonuçları.

Clearness İndex	Değerlendirme Parametleri	
	MSE	RMSE
Eğitim	0.0066	0.0816
Test	0.0084	0.0918

İkinci olarak, bu çalışmada korelasyon katsayısı kullanılmıştır. Korelasyon katsayısı, iki sürekli değişken arasındaki olası bir doğrusal ilişkiyi değerlendirmek için kullanılan istatistiksel bir yöntemdir. Burada 2013 yılı clearness indeksi verilerinin eğitiminde girdi olarak kullanılacak verilere karar vermek için bir korelasyon katsayısı hesaplanır. MATLAB'da "corr2" korelasyon komutu kullanılarak, clearness index verilerinin kendi içinde bazı korelasyonları hesaplanır. Bu, bir saat önceki clearness index ile bir saat sonraki, iki saat önceki clearness index ile iki saat sonraki ve bir gün önceki clearness index ile bir gün sonraki clearness index korelasyonuna bakacağımız anlamına gelir. Sonuçlar Çizelge 4.6'de aşağıdaki gibi gösterilmektedir.

Çizelge 4.6 Korelasyon sonuçları.

Hipotez	Korelasyon Katsayısı
Corr2(x1,y1)	0.8632
Corr2(x2,y2)	0.7262
Corr2(x3,y3)	0.8893

Clearness index değerinin modellenmesinde hatanın istenilen seviyelere düşürülmesinin ardından hibrit modelin tasarlanması aşamasına geçilmiştir.

4.5 Hibrit Yöntemin Oluşturulması

Hibrit yöntem, clearness index değerine bağlı olarak bir karar verme mekanizmasına dayalı olarak oluşturulmuştur. Bu kapsamda, üç farklı model kullanılmış ve clearness index aralığına göre güneş radyasyonu üç yöntemle (YSA, NARX ve Ridge regresyon) modellenmiştir. Bulutluluk durumunu ifade eden 3 farklı clearness index aralığı belirlenmiş ve her bir aralıkta, kullanılan yöntemlerin başarısı irdelenmiştir. Bu kapsamda 0 ile 0,35 aralığı, 0,35 ile 0,7 aralığı ve 0,7 ile 1 aralığı, çok bulutlu, bulutlu ve açık havaya karşılık geldiği düşünüldükçe, belirlenmiştir. Sonra her bir veri 3 yöntemle de NARX, YSA bir de Ridge regresyon ile eğitilip, modellerin sonuçları aşağıda Çizelge 4.7'de gösterilmiştir:

Çizelge 4.7 Modellerin sonuçları.

MODELLER	YSA	NARX	RR
$0 < \text{Clearness} < 0.35$	37.5178	39.6467	47.4301
$0.35 < \text{Clearness} < 0.70$	77.9898	78.0229	85.9685
$0.70 < \text{Clearness} < 1$	55.6163	51.4604	53.5455

Çizelge 4.7'den görüleceği gibi 0 ile 0,35 aralığında en başarılı model YSA ile oluşturulmuş, sonrasında ise NARX ve RR gelmektedir. 0,35 ile 0,7 aralığında en başarılı model YSA ile elde edilirken onu NARX ve RR takip etmektedir. 0,7 ile 1 aralığında ise en başarılı yöntem NARX olurken, onu RR ve YSA takip eder. Bu sonuçlara göre iki aralıkta YSA daha başarılı bir tahmin modeli sağlarken, bir aralıkta NARX en başarılı sonucu vermiştir. Bu Ridge regresyonun, oluşturulan hibrit modelde yer almayacağı anlamına gelmektedir.

Oluşturulan hibrit yöntemde, hangi yöntemin kullanılacağına karar verme prensibine ait pseudo kod Şekil 4.17'de gösterilmiştir.


```
% hibrit metot
% Clearnessindexi YSA ile tahmin et
for i = 1:m % burada 'm', veri sayısıdır.
    if clearnessindex(i) < 0.35
        Tahmin(i) = YSA(i)
    elseif clearnessindex(i) > 0.35 & clearnessindex(i) < 0.70
        Tahmin(i) = YSA(i)
    else
        Tahmin(i) = NARX(i)
end
```

Şekil 4.17 Hibrit Yöntemin Oluşturulması.

YSA-NARX-RR modelleri ve hibrit modelin 2014 yılı için Mardin'de saatlik güneş ışınımını tahmin etme performansının sonuçlarının bir özeti Çizelge 4.8'de gösterilmektedir.

Çizelge 4.8 YSA-NARX-RR modellerinin ve hibrit modelin tahmin sonuçlarının bir özeti.

Yöntem eğitim işlevini	Değerlendirme Parametreleri	
	MSE	RMSE
RR	14356.3531	119.8180
NARX	3476.6353	58.9630
YSA	4577.9161	67.6603
Önerilen Yöntem	3355.8733	57.9299



Şekil 4.18 Ölçülen ve tahmin edilen değerleri karşılaştıran grafikler.

Yukarıdaki Çizelge 4.8, tüm modeller için RMSE'nin 119.81 ile 57.92 aralığında, MSE'nin 14356.35 ile 3355.87 arasında olduğu görülmektedir. Performans göstergelerinin aralığı, hibrit yöntemin iyi bir tahmin yeteneği sağladığını ve tekli modellerle karşılaştırılabilir olduğunu göstermektedir. Modellerin karşılaştırılması, hibrit modelin NARX, RR ve YSA için tek modelden daha iyi performans gösterdiğini göstermektedir. Araştırılan üç tekli model arasında hibrit modelin RMSE değerlerine göre en iyi model olduğu kanıtlanmıştır, bu da bu hibrit modelin tahmin hatalarında en küçük ortalama dağılıma ve genel yanlılığa sahip olduğunu gösterir. Ayrıca Çizelge 4.8, hibrit model için hata indekslerinin, karşılık gelen tekli YSA modeline çok yakın olduğunu ortaya koymaktadır. Bunun nedeni, tüm metrikleri üstün değerlere sahip olduğundan, YSA tabanlı modelin NARX, RR'den daha iyi performansa sahip olmasından kaynaklanmaktadır. NARX ve RR'nin aksine YSA, güneş radyasyonunun

kaotik yapısı ile girdi meteorolojik faktörleri arasındaki hem doğrusal hem de doğrusal olmayan ilişkileri hesaba katar.

Bu nedenle, NARX-YSA tahmininin hibridizasyonunun, RMSE'yi yaklaşık %1 oranında azaltarak çıktıyı iyileştirdiği sonucuna varılabilir. Bu, tek değişkenli zaman serilerinin uzun vadeli (çok adımlı) tahminine kolayca ve verimli bir şekilde uygulanabilen NARX ağının sonucudur. Aynı zamanda, mimarilerindeki yapay sinir ağları (YSA), biyolojik sinir sistemlerini taklit etmek için tasarlanmış bir esnek doğrusal olmayan modeller sınıfını oluşturur. Bayesian-düzenleme (*br*) eğitim fonksiyonunun, işlem hızı ve sonuçların doğruluğu açısından bu Levenberg-Marquardt (*tr*) modelden daha iyi performans gösterdiğini de belirtmek gerekir. Bu nedenle, yine, tahminler uzun bir süre boyunca toplandığında hibrit modellerin eşdeğer tekli modellerinden daha iyi tahmin performansı sağlayacağı düşünülmektedir. Bu sonuçlar aynı zamanda hibrit yöntemin en iyi tahmin modeli olduğunu ve tekli modellere göre genel üstünlüğünü teyit etmektedir.

5. TARTIŞMA ve SONUÇ

Güneş ışıının tahmini, güneş enerjisi mühendisliğinde önemli bir rol oynamaktadır. Bir güneş enerji sisteminin üretimini belirleyecek en temel girdi güneş ışıının değeridir ve bu sistemi verimli bir şekilde planlamak ve yönetmek için değişken yapıda olan güneş ışıının belirli bir andaki değerinin doğru olarak belirlenebilmesi gerekir. Ayrıca güneş ışıını ölçüm istasyonlarının her yerde bulunmaması sebebiyle güneş radyasyonu, çeşitli güneş radyasyonu tahmin modelleri kullanılarak bu yerler için doğru bir şekilde tahmin edilmelidir. Bu kapsamda literatürde güneş ışıının tahmini için birçok yöntem geliştirilmiştir. Bu kapsamda geliştirilen güneş enerjisi modellerinin temel olarak doğrusal ve doğrusal olmayan modeller olarak ayrıldığı görülmektedir (Khatib vd. 2012, Yörükoğlu ve Çelik 2006, Beşarat vd. 2013). Güneş ışıının verisi incelendiğinde içerisinde doğrusal ve doğrusal olmayan bileşenler içerdiği görülmektedir. Güneş ve dünyanın hareketine bağlı olarak güneş ışıında beklenen bir değişkenlik olmakla beraber, atmosferik olaylar sebebiyle beklenmedik değişiklikler de gözlenmektedir. Bu sebeple güneş ışıının verisi bir bütün olarak incelendiğinde, bahsedilen sebeplerden dolayı stokastik bir yapıda olduğu gözlenmektedir. Bu sebeple literatürde güneş ışıının bu farklı yapılarıdaki bileşenlerini ayrı ayrı modelleme yeteneğine sahip hibrit yöntemler geliştirildiği gözlenmektedir. Buradan yola çıkarak, gerçekleştirilen tez çalışmasında, Türkiye’de bulunan Mardin iline ait güneş ışıının verilerinin modellenmesi için hibrit bir yöntem geliştirilmiştir.

Hibrit yöntem tasarımında YSA, NARX ve Ridge regresyon yöntemlerinin bir kombinasyonunun kullanılması planlanmıştır. Yukarıda bahsedilen konular dikkate alınarak bulutluluk indeksi değerine bağlı olarak güneşlenme durumu üç ayrılmıştır. Bulutluluk indeksinin 0 ile 0,35 aralığında olması durumunun çok bulutluluğa, 0,35 ile 0,7 arasında olması bulutluluğa ve 0,7’den büyük olması ise açık havaya karşılık gelecek şekilde, güneş ışıının verileri üç farklı sınıfa ayrılmıştır. Her biri farklı karaktere sahip üç yöntemin her bir sınıftaki modelleme başarısı incelenmiş ve hangi aralıkta hangi yöntemin daha başarılı sonuçlar verdiği araştırılmıştır. Bu aşamada bulutlu ve çok bulutlu olarak sınıflandırılmış koşullarda YSA ile daha başarılı tahminler yapılırken, açık gökyüzü olarak sınıflandırılan durumda ise NARX yönteminin daha başarılı

sonular verdiđi grlmřtr. Ridge regresyon yntemi ise bazı aralıklarda en iyi ynteme yakın hata deđerleri sađlamasına rađmen, hibir aralıktaki en bařarılı yntem olamamıřtır. Bu sebeple nerilen hibrit yntemde Ridge regresyon yntemi bulunmamaktadır. nerilen hibrit yntemde ncelikli olarak bulutluluk indeksi tahmin edilir ve tahmin edilen bulutluluk indeksin yer aldıđı aralıđa gre kullanılacak ynteme karar verilir. Bu kapsamda bulutluluk indeksi verileri YSA kullanılarak modellenmiřtir. Hibrit modelin bařarısındaki kritik ařamalardan bir tanesi, bulutluluk indeksinin bařarılı bir řekilde tahmin edilmesidir. Bulutluluk indeksinin tahmini iin, eđitimde kullanılan verilerde 0,0816, test iin kullanılan verilerde ise 0,0918 RMSE deđerleri elde edilmiřtir. nerilen hibrit yntem ile elde edilen RMSE deđerleri $57,92 \text{ W/m}^2$ olarak belirlenmiřtir. Verilerin tamamının NARX ile tahmin edilmesi durumunda RMSE deđerleri $67,66 \text{ W/m}^2$ olarak hesap edilirken, sadece YSA kullanılması durumunda ise RMSE deđerleri $58,96 \text{ W/m}^2$ olarak hesap edilmiřtir. Bu, tahmin iin sadece YSA'nın kullanıldıđı duruma gre yaklaşık %1,76, sadece NARX'in kullanıldıđı duruma gre ise yaklaşık %14,39 iyileřme elde edildiđi anlamına gelmektedir. Bulutluluk indeksinin daha yksek dođrulukta tahmin edilmesi durumunda, hibrit yntemin bařarısının da artacađı aıktır. Ayrıca nerilen yntemde kullanılan modellerin tahmin dođruluđunun artması da, bu modelin bařarısını olumlu ynde etkileyecektir. Gerekleřtirilen alıřmada, mevcut olan iki yıllık verinin, bir yılı eđitimde kalan kısmı ise test iin kullanılmıřtır. Eđitimde daha fazla verinin kullanılması durumunda farklı řartlarda yntemlerin bařarı durumlarının daha dođru belirlenebileceđi, bunun da yntemin bařarısını artıracadıđı dřnlmektedir. Bu tez alıřmasında bir hibrit yntem oluřturma mantıđı ortaya koyulmuř olup, farklı yntemler kullanılarak daha bařarılı tahmin yapıları oluřturulabilecektir. Farklı yntemlerin byle bir yapıda bařarılarının incelenmesinin gelecek alıřmalar iin iyi bir arařtırma konusu olduđu dřnlmektedir. Son olarak, hibrit yntemi kullanarak gneř radyasyonunun ngrlmesi dikkat ekicidir, yle ki gelecekte arařtırmacıların sorunları ozmek iin ele alacakları temel konulardan biri olacak enerji geiřine katkıda bulunmak iin alternatif enerjinin boyutlandırılması, retilmesi ve ynetiminde faydalı bir alternatif olabilirler.

6. KAYNAKLAR

- Arroyo M, F.R., Miguel, L.J., 2020. The Role of Renewable Energies for the Sustainable Energy Governance and Environmental Policies for the Mitigation of Climate Change in Ecuador. *Energies*, 13, 3883.
- Ayodele, T.R., Ogunjuyigbe, A.S.O., Monyei, C.G., 2016. On the global solar radiation prediction methods. *Journal of Renewable and Sustainable Energy*, 8, Article number 023702.
- Assas, O., Bouzgou, H., Fetah, S., Salmi, M., Boursas, A., 2014, January. Use of the artificial neural network and meteorological data for predicting daily global solar radiation in Djelfa, Algeria. In 2014 International Conference on Composite Materials & Renewable Energy Applications (ICCMREA) 1-5. IEEE.
- Al-Alawi, S.M., Al-Hinai, H.A., 1998. An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation. *Renewable Energy*, 14, 199-204.
- Andalib, A. and Atry, F., 2009. Multi-step ahead forecasts for electricity prices using NARX: A new approach, a critical analysis of one-step ahead forecasts. *Energy Conversion and Management*, 50, 739-747.
- Azimi, R., Ghayekhloo, M., Ghofrani, M., 2016. A hybrid method based on a new clustering technique and multilayer perceptron neural networks for hourly solar radiation forecasting. *Energy Conversion and Management*, 118, 331-344.
- Akarslan, E., 2014. Güneş enerjisinin tahmininde sinyal işleme tabanlı yeni yaklaşımlar.
- Alam, F., Rehman, S.U., Rehman, S., JAHANGIR, M., Shoaib, M., Siddiqui, I. and Ulfat, I., 2019. Empirical model development for the estimation of clearness index using meteorological parameters. *Turkish Journal of Electrical Engineering & Computer Sciences*, 27, 4429-4441.
- Abdelgadir, G.A. and Eledum, H., 2016. A Comparison Study of Ridge Regression and Principle Component Regression with Application.

- Al-Enezi, J.R., Abbod, M.F., Alsharhan, S., 2010. Artificial immune systems-models, algorithms and applications.
- Ahmad, M.J., Tiwari, G.N., 2011. Solar radiation models—A review. *International Journal of Energy Research*, 35, 271-290.
- Boussaada, Z., Remaci, A., Curea, O., Camblong, H., Bellaaj, N., 2017, June. Prediction of the daily direct solar radiation using nonlinear autoregressive exogenous (narx) network model. In *SEEP 2017-10th International Conference on Sustainable Energy and Environmental Protection*.
- Boussaada, Z., Curea, O., Remaci, A., Camblong, H., Mrabet Bellaaj, N., 2018. A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation. *Energies*, 11, 620.
- Besharat, F., Dehghan, A.A. and Faghih, A.R., 2013. Empirical models for estimating global solar radiation: A review and case study. *Renewable and Sustainable Energy Reviews*, 21, 798-821.
- Bakırcı, K., 2009. Yatay Yüzeye Gelen Anlık Global Güneş Işınımının Tahmini İçin Basit Bir Hesaplama Metodu. *Isı Bilimi ve Tekniği Dergisi*, 29, 53-58.
- Biçer, A., 2017. Enerji Talep Tahminine Yönelik Program Geliştirme ve Bir Bölge için Uygulaması (Master's thesis).
- Diagne, M., David, M., Boland, J., Schmutz, N., Lauret, P., 2014. Post-processing of solar irradiance forecasts from WRF model at Reunion Island. *Solar Energy*, 105, 99-108.
- Diaconescu, E., 2008. The use of NARX neural networks to predict chaotic time series. *Wseas Transactions on computer research*, 3, 182-191.
- Dong, Z., Yang, D., Reindl, T., Walsh, W.M., 2014. Satellite image analysis and a hybrid ESSS/ANN model to forecast solar irradiance in the tropics. *Energy Conversion and Management*, 79, 66-73.
- Dombaycı, Ö.A., Gölcü, M., 2009. Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey. *Renewable Energy*, 34, 1158-1161.

- Deniz, E., Kemal, A.T.İ.K., 2007. Güneş Işınım Şiddeti Tahminlerinde Yapay Sinir Ağları Ve Regresyon Analiz Yöntemleri Kullanımının İncelenmesi. Isı bilimi ve tekniği dergisi, 27, 15-20.
- Doğan, G., 2010. Yapay sinir ağları kullanılarak Türkiye'deki özel bir sigorta şirketinde portföy değerlendirmesi. Yüksek Lisan Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Di Piazza, A., Di Piazza, M.C., Vitale, G., 2016. Solar and wind forecasting by NARX neural networks. Renewable Energy and Environmental Sustainability, 1, 39.
- Eltamaly, A.M., Mohamed, M.A., 2018. Optimal sizing and designing of hybrid renewable energy systems in smart grid applications. In Advances in Renewable Energies and Power Technologies 231-313. Elsevier.
- Fadare, D.A., 2009. Modelling of solar energy potential in Nigeria using an artificial neural network model. Applied energy, 86, 1410-1422.
- Fu, W., Wang, K., Li, C., Li, X., Li, Y. and Zhong, H., 2018. Vibration trend measurement for a hydropower generator based on optimal variational mode decomposition and an LSSVM improved with chaotic sine cosine algorithm optimization. Measurement Science and Technology, 30, Article number 015012.
- Garg, H.P., 1982. Treatise on solar energy. John Wiley & Sons.
- Güçlü, Y.S., 2019. Angström-Prescott Modelinin Polinom ile Geliştirilmesi ve Diyarbakır Güneş Işınımı Verilerine Uygulanması. Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi, 7, 75-88.
- Hepbasli, A., Alsuhaibani, Z., 2011. A key review on present status and future directions of solar energy studies and applications in Saudi Arabia. Renewable and sustainable energy reviews, 15, 5021-5050.
- Hamzaçebi, C., 2011. Yapay sinir ağları: tahmin amaçlı kullanımı MATLAB ve Neurosolutions uygulamalı. Ekin Basım Yayın Dağıtım.
- Hoerl, A.E., Kennard, R.W., 1970. Ridge regression: Biased estimation for nonorthogonal problems. Technometrics, 12, 55-67.

- Horel, A.E., 1962. Applications of ridge analysis to regression problems. Chem. Eng. Progress., 58, 54-59.
- Hoerl, A.E., Kennard, R.W., 1968, January. On regression analysis and biased estimation. In Technometrics (Vol. 10, No. 2, p. 422). 1429 DUKE ST, ALEXANDRIA, VA 22314: AMER STATISTICAL ASSOC.
- Hoerl, A.E. (1964). Ridge analysis. Chemical Engineering Progress symposium Series 60, 67-77.
- IEA 2013, "Renewable Energy Medium-Term Market Report 2013 Market Trends and Projections 2018". OECD/IEA International Energy Agency.
- IEA 2013, Determinants of Renewable Energy Resources and Their Relationship Between Economic Growth: The Case of Developing Countries.
- IPCC 2013, "Climate Change 2013: The Physical Science Basis". Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change.
- Ibrahim, S., Daut, I., Irwan, Y.M., Irwanto, M., Gomesh, N. and Farhana, Z., 2012. Linear regression model in estimating solar radiation in Perlis. Energy Procedia, 18, 1402-1412.
- Jafarzadeh, S., Fadali, M.S., Evrenosoglu, C.Y., 2012. Solar power prediction using interval type-2 TSK modeling. IEEE Transactions on Sustainable Energy, 4, 333-339.
- Kinloch, D.H., Parmelee, J.M., Wicks, F.E., Becker, M., Yerazunis, S., 1982. Impacts of solar heating options upon electric power systems. IEEE Transactions on Power Apparatus and Systems, 6, 1271-1280.
- Khatib, T., Mohamed, A. and Sopian, K., 2012. A review of solar energy modeling techniques. Renewable and Sustainable Energy Reviews, 16, 2864-2869.
- Khan, M.M., Ahmad, M.J., 2012. Estimation of global solar radiation using clear sky radiation in Yemen. Journal of Engineering Science & Technology Review, 5.
- Kalogirou, S.A., 2013. Solar energy engineering: processes and systems. Academic Press.

- Kalogirou, S.A., 1999. Applications of artificial neural networks in energy systems. *Energy Conversion and Management*, 40, 1073-1087.
- Koca, A., Oztop, H.F., Varol, Y., Koca, G.O., 2011. Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey. *Expert Systems with Applications*, 38, 8756-8762.
- Kharseh, M., Solar Radiation Calculations. Course Notes.
- Khalaf, G., Shukur, G., 2005. Choosing ridge parameter for regression problems.
- Koutsoyiannis, D., Xanthopoulos, T., 1989. On the parametric approach to unit hydrograph identification. *Water resources management*, 3, 107-128.
- Lazzús, J.A., Ponce, A.A.P., Marín, J., 2011. Estimation of global solar radiation over the city of La Serena (Chile) using a neural network. *Applied Solar Energy*, 47, 66-73.
- Linares-Rodríguez, A., Ruiz-Arias, J.A., Pozo-Vázquez, D., Tovar-Pescador, J., 2011. Generation of synthetic daily global solar radiation data based on ERA-Interim reanalysis and artificial neural networks. *Energy*, 36, 5356-5365.
- Mohammad, S.T., Al-Kayiem, H.H., Aurybi, M.A., Khelif, A.K., 2020. Measurement of global and direct normal solar energy radiation in Seri Iskandar and comparison with other cities of Malaysia. *Case Studies in Thermal Engineering*, 18, 100591.
- Mohandes, M., Rehman, S., Halawani, T.O., 1998. Estimation of global solar radiation using artificial neural networks. *Renewable energy*, 14, 179-184.
- Mohanty, S., Patra, P.K., Sahoo, S.S., 2015, December. Prediction of global solar radiation using nonlinear auto regressive network with exogenous inputs (narx). In 2015 39th National Systems Conference (NSC), 1-6. IEEE.
- Mohammed, L.B., Hamdan, M.A., Abdelhafez, E.A., Shaheen, W., 2013. Hourly solar radiation prediction based on nonlinear autoregressive exogenous (Narx) neural network. *JJMIE*, 7.

- Massaoudi, M., Chihi, I., Sidhom, L., Trabelsi, M., Refaat, S.S. and Oueslati, F.S., 2019. A novel approach based deep RNN using hybrid NARX-LSTM model for solar power forecasting. arXiv preprint arXiv:1910.10064.
- Nazaripouya, H., Wang, B., Wang, Y., Chu, P., Pota, H.R. and Gadh, R., 2016, May. Univariate time series prediction of solar power using a hybrid wavelet-ARMA-NARX prediction method. In 2016 IEEE/PES Transmission and Distribution Conference and Exposition (T&D), 1-5.
- Owusu, P.A. and Asumadu-Sarkodie, S., 2016. A review of renewable energy sources, sustainability issues and climate change mitigation. Cogent Engineering, 3, Article number 1167990.
- O'Neill, S., 2020. Global CO2 emissions level off in 2019, with a drop predicted in 2020. Engineering (Beijing, China), 6, 958.
- Omar, H., Hoang, V.H., Liu, D.R., 2016. A hybrid neural network model for sales forecasting based on ARIMA and search popularity of article titles. Computational intelligence and neuroscience, 1-9.
- Özçalık, H.R., Küçüktüfekçi, A., 2003. Dinamik Sistemlerin Yapay Sinir Ağları ile Düz ve Ters Modellenmesi. KSÜ Fen ve Mühendislik Dergisi, 6, 26-35.
- Premalatha, N., Valan Arasu, A., 2016. Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. Journal of applied research and technology, 14, 206-214.
- Picton, P. (2000). Neural network (second ed.). UK: Antony Rowe Ltd.
- Pisoni, E., Farina, M., Carnevale, C., Piroddi, L., 2009. Forecasting peak air pollution levels using NARX models. Engineering Applications of Artificial Intelligence, 22, 593-602.
- Qazi, A., Fayaz, H., Wadi, A., Raj, R.G., Rahim, N.A. and Khan, W.A., 2015. The artificial neural network for solar radiation prediction and designing solar systems: a systematic literature review. Journal of cleaner production, 104, 1-12.

- Riley, J.D., 1955. Solving systems of linear equations with a positive definite, symmetric, but possibly ill-conditioned matrix. *Mathematical tables and other aids to computation*, 96-101.
- Rusen, S.E., Konuralp, A., 2020. Quality control of diffuse solar radiation component with satellite-based estimation methods. *Renewable Energy*, 145, 1772-1779.
- Rehman, S., Mohandes, M., 2009. Estimation of diffuse fraction of global solar radiation using artificial neural networks. *Energy Sources, Part A*, 31, 974-984.
- Rabehi, A., Guermoui, M., Lalmi, D., 2020. Hybrid models for global solar radiation prediction: a case study. *International Journal of Ambient Energy*, 41, 31-40.
- Renné, D.S., 2016. Resource assessment and site selection for solar heating and cooling systems. In *Advances in Solar Heating and Cooling* (13-41). Woodhead Publishing.
- Sharma, S., Bhatt, R., 2019. Predicting Daily Incoming Solar Energy Output using Weather Data.
- Sözen, A., Arcaklıoğlu, E., Özalp, M., Çağlar, N., 2005. Forecasting based on neural network approach of solar potential in Turkey. *Renewable Energy*, 30, 1075-1090.
- Sansa, I., Bellaaj, N.M., 2018. Solar Radiation Prediction Using NARX Model. In *Advanced Applications for Artificial Neural Networks*. IntechOpen.
- Serttaş, F., 2015. Güneş Işınım Şiddeti Tahminine Örüntü Tarama Tabanlı Yeni bir Yaklaşım (Master's thesis).
- Şenkal, O., Kuleli, T., 2009. Estimation of solar radiation over Turkey using artificial neural network and satellite data. *Applied energy*, 86, 1222-1228.
- Taktak, F., Mehmet, I.L.I., 2018. Güneş Enerji Santrali (GES) Geliştirme: Uşak Örneği. *Geomatik*, 3, 1-21.
- Tikyaa, E.V., Echi, M.I., Isikwue, B.C., Amah, A.N., 2018. A hybrid SARIMA-NARX nonlinear dynamics model for predicting solar radiation in Makurdi. *Int. J Math. Computat. Sci*, 4, 35-47.

- Üstündağ, E., 2017. Doğrusal Tahmin Filtrelerinin Yenilenebilir Enerji Sistemlerinde Kullanımı İçin Arayüz Tasarımı (Master's thesis).
- Voyant, C., Muselli, M., Paoli, C., Nivet, M.L., 2012. Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. *Energy*, 39, 341-355.
- Voyant, C., Muselli, M., Paoli, C., Nivet, M.L., 2011. Optimization of an artificial neural network dedicated to the multivariate forecasting of daily global radiation. *Energy*, 36, 348-359.
- Vignola, F., Michalsky, J., Stoffel, T., 2019. Solar and infrared radiation measurements. CRC press.
- Wenxian, L., 1988. A general correlation for estimating the monthly average daily direct radiation incident on a horizontal surface in Yunnan Province, China. *Solar Energy*, 41, 1-3.
- Yadav, A.K., Chandel, S.S., 2014. Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and sustainable energy reviews*, 33, 772-781.
- Yadav, A.K., Chandel, S.S., 2012. Artificial neural network based prediction of solar radiation for Indian stations. *International Journal of Computer Applications*, 50.
- Yorukoglu, M., Celik, A.N., 2006. A critical review on the estimation of daily global solar radiation from sunshine duration. *Energy Conversion and Management*, 47, 2441-2450.
- Zameer, A., Shahid, F., Afzal, M., Hassan, M., 2020. Intelligent forecast models for daily solar energy prediction.