



**GÖLE BELEDİYESİ GÜNEŞ ENERJİ SANTRALİ
ÜRETİM VERİLERİNİN METEOROLOJİK
VERİLERE BAĞLI OLARAK YAPAY ZEKÂ
YÖNTEMLERİ İLE TAHMİNİ**

Erdi MORKOÇ

**Yüksek Lisans Tezi
Elektrik Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Kağan Koray AYTEN**

**2024
Her hakkı saklıdır..**



FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ

GÖLE BELEDİYESİ GÜNEŞ ENERJİ SANTRALİ ÜRETİM VERİLERİNİN
METEOROLOJİK VERİLERE BAĞLI OLARAK YAPAY ZEKÂ
YÖNTEMLERİ İLE TAHMİNİ

Erdi MORKOÇ

Tez Danışmanı: Doç. Dr. Kağan Koray AYTEN

Anabilim Dalı: Elektrik Elektronik Mühendisliği

Erzurum

2024

Her hakkı saklıdır

T.C.
ERZURUM TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ ONAY FORMU

**GÖLE BELEDİYESİ GÜNEŞ ENERJİ SANTRALİ ÜRETİM VERİLERİNİN
METEOROLOJİK VERİLERE BAĞLI OLARAK YAPAY ZEKÂ
YÖNTEMLERİ İLE TAHMİNİ**

Doç. Dr. Kağan Koray AYTEN danışmanlığında, Erdi MORKOÇ tarafından hazırlanan bu çalışma 14 / 11 / 2024 tarihinde aşağıdaki jüri tarafından Elektrik Elektronik Mühendisliği Ana Bilim Dalı'nda Yüksek Lisans tezi olarak **Oy birliği ile (3/3)** ile kabul edilmiştir.

Başkan	: Prof. Dr. İsmail Hakkı ÇAVDAR	İmza	:
Üye	: Prof. Dr. Ahmet DUMLU	İmza	:
Üye	: Doç. Dr. Kağan Koray AYTEN	İmza	:

Yukarıdaki sonucu onaylıyorum

Doç. Dr. Bünyamin ÖZGERİŞ
Enstitü Müdürü

*Bu tez çalışması tarafından nolu proje ile desteklenmiştir.

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

14 / 11 / 2024

İmzası

Erdi MORKOÇ

ÖZET

YÜKSEK LİSANS TEZİ

GÖLE BELEDİYESİ GÜNEŞ ENERJİ SANTRALİ ÜRETİM VERİLERİNİN METEOROLOJİK VERİLERE BAĞLI OLARAK YAPAY ZEKÂ YÖNTEMLERİ İLE TAHMİNİ

Erdi MORKOÇ

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Seçin Ana Bilim Dalı

Danışman: Doç. Dr. Kağan Koray AYTEN

Her geçen gün teknolojiadaki gelişmeler ile birlikte enerji talebinin sürekli artışı, fosil yakıtların tükenme sürecine girmesi ve çevresel etkilerin daha fazla dikkate alınması, yenilenebilir enerji kaynaklarına olan ihtiyacı giderek artırmıştır. Özellikle güneş enerjisi, son dönemde önemli bir gelişim göstermiştir. Bu çalışmanın amacı, güneş enerjisinin genel özelliklerini incelemek ve güneş enerjisi santrallerinin üretim verilerini meteorolojik verilere dayalı olarak yapay zeka yöntemleriyle tahmin etmektir. Çalışmada, çok katmanlı yapay sinir ağları (ÇKYSA) ve uyarlamalı bulanık yapay sinir ağı çıkarım sistemi (ANFIS) kullanılarak çalışmanın yapıldığı bölge için ileriye dönük olarak güneş enerjisi üretimi tahmin edilmiştir. ÇKYSA yöntemiyle yapılan tahminlerde, en iyi sonuçların Levenberg-Marquardt (trainlm) algoritması ile elde edildiği bulunmuştur. ANFIS yönteminde ise Dsigmf üyelik fonksiyonu tipi ile 2-2-2 yapılandırmasına sahip üyelik fonksiyonları kullanılarak oluşturulan modelin en yüksek performansı gösterdiği tespit edilmiştir. Bu yöntemler, enerji sektöründe santrallerin üretim verilerinin tahmin edilmesi konusunda etkin bir şekilde uygulanabilir.

2024, 87 sayfa

Anahtar Kelimeler: Çok Katmanlı Yapay Sinir Ağı, ANFIS, Yapay Zeka

ABSTRACT

MS. Thesis

PREDICTION OF THE PRODUCTION DATA OF GÖLE MUNICIPALITY SOLAR ENERGY POWER PLANT BASED ON METEOROLOGICAL DATA USING ARTIFICIAL INTELLIGENCE METHODS

Erdi MORKOÇ

Erzurum Technical University
Graduate School of Natural and Applied Sciences
Department of Electrical Electronic Engineering

Supervisor: Assoc. Prof. Dr. Kağan Koray AYTEN

With technological developments day by day, the continuous increase in energy demand, the depletion of fossil fuels and the increasing monitoring of growth, the need for alternative energy sources has gradually increased. Especially solar energy has shown significant development recently. For this purpose, the general characteristics of solar energy and the production parts of solar power plants can be predicted using artificial intelligence methods on a meteorological basis. In the study, solar panel production was estimated using multilayer artificial neural networks (MLNN) and adaptive neural network extraction system (ANFIS). In the predictions made with the ÇKYSA method, the best results are in countries with Levenberg-Marquardt (trainlm) students and the elderly. In the ANFIS method, it was determined that the highest performance was shown in the recording time model with the Dsgmf recording function type and the 2-2-2 capacity. It is clearly observed from the publication graphs that the predictions made with both models show a high accuracy rate with the measurement data. This can be effectively applied in estimating the production data of power plants in the energy sector

2024, 87 page

Keywords: Multilayer Artificial Neural Network, ANFIS, Artificial intelligence

TEŞEKKÜR

Bu tez çalışmasında bana rehberlik eden, samimiyeti ve yardımseverliği ile sorularıma yanıt veren değerli tez danışmanım Sayın Doç. Dr. Kağan Koray AYTEN'e, eğitim ile ilgili her zaman talepte bulunan kişilere yardımını ve desteğini esirgemeyen Ardahan ili Meteoroloji Müdürü Sayın Hüseyin GEÇGEL'e fikirleri ve çözümleriyle her zaman destek olan arkadaşım Öğretim Görevlisi Sayın Mahmut KENAR 'a öncelikle teşekkür ederim. Tez sürecimde her daim yanımda olarak kendimi geliştirmemi teşvik eden sevgili eşim Zeynep AKTAŞ MORKOÇ'a ve tez çalışmam boyunca bana ilham veren, beni sürekli motive eden, yaşamımda büyük bir sevinç kaynağı olan oğlum Metehan Ahmet MORKOÇ 'a şükranlarımı sunarım

Erdi MORKOÇ
Kasım 2024

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	4
2.1. Literatür Özeti	4
2.2. Güneş Enerjisi Tarihsel Gelişimi	11
2.3. Güneş Enerji Santralleri ve Çalışma Prensibi	12
2.4. İşletme ve Bakım Stratejileri.....	13
2.5. Fotovoltaik Paneller	13
2.5.1. Monokristal silisyum hücreler.....	15
2.5.2. Polikristal silisyum hücreler.....	16
2.5.3. Amorf silisyum hücreler	17
2.6. Solar Eviriciler	18
2.6.1. Off-Grid inverterler.....	19
2.6.2. On-Grid inverterler.....	19
2.6.3. Hibrit inverterler.....	19
2.7. Trafo.....	19
2.8. Panel Taşıyıcı Sistemler	20
2.9. Çift Yönlü Elektrik Sayacı	21
2.10. Türkiye'nin ve Dünya'nın Yenilenebilir Enerji Durumu.....	22
2.11. Ardahan Gölü Bölgesinin Coğrafi Özellikleri.....	27
2.12. İklim Verileri ve Analizi	27
2.13. Güneşlenme Süresi ve Radyasyon Değerleri	28
2.14. Ardahan Gölü Bölgesi ve Güneş Enerji Potansiyeli	30
2.15. Santralin Teknik Özellikleri.....	30

3. MATERYAL VE YÖNTEM	31
3.1. Yapay Zeka	31
3.1.1. Yapay sinir ağları (YSA)	32
3.1.1.1. Trainlm (levenberg-marquardt algoritması).....	37
3.1.1.2. Trainbr (bayesian regularization algoritması).....	38
3.1.1.3. Trainscg (scaled conjugate gradient algoritması)	39
3.1.2. Anfis.....	39
4. BULGULAR	45
4.1. Çok Katmanlı Yapay Sinir Ağı Uygulaması.....	45
4.1.1. Trainlm değerlendirme ölçütü.....	47
4.1.2. Trainscg değerlendirme ölçütü.....	53
4.1.3. Trainbr değerlendirme ölçütü.....	59
4.2. Uyarlamalı Bulanık Yapay Sinir Ağı Uygulaması (ANFIS)	65
4.2.1. Anfis 2-2-2	66
4.2.2. Anfis 3-3-3	70
4.2.3. Anfis 4-4-4	75
5. SONUÇ ve ÖNERİLER	81
KAYNAKLAR	84

SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
%	Yüzde
Ah	Amper saat
C°	Santigrat derece
GW	Giga watt
kWh	Kilo watt-saat
kWh/m ²	Kilo watt saat/metre kare
MW	Mega watt
W/m ²	Watt/metre kare

ŞEKİLLER DİZİNİ

Şekil 2.1. Fotovoltaik panel yapısı (Özdemir 2022)	14
Şekil 2.2. Fotovoltaik panel çalışma prensibi (Özdemir 2022)	15
Şekil 2.3. Monokristal silisyum hücre yapısı (Özdemir 2022)	16
Şekil 2.4. Polikristal silisyum hücre yapısı (Özdemir 2022)	17
Şekil 2.5. Amorf silisyum hücre yapısı (Özdemir 2022)	18
Şekil 2.6. Solar evirici.....	18
Şekil 2.7. Kabin tipi trafo köşk	20
Şekil 2.8. Zemin tipi panel taşıyıcı sistem	21
Şekil 2.9. Çift yönlü sayaç	22
Şekil 2.10. Dünyanın güneş ışınlımı (Yalçın 2019).....	23
Şekil 2.11. Sahra Çölü'nde 800x800 km2 alan (Yalçın 2019).	24
Şekil 2.12. Ardahan ili güneş radyasyonu (GEPA)	28
Şekil 2.13. Göle ilçesi aylık güneşlenme tablosu (GEPA)	29
Şekil 2.14. Göle GES kullanılan paneller ve üretim değerleri (GEPA).....	29
Şekil 3.1. Sinir ağı yapısı	33
Şekil 3.2. İleri beslemeli ÇKYSA yapısı	36
Şekil 4.1. ÇKYSA trainlm 10 nöronlu tahmin sonuçları	48
Şekil 4.2. Trainlm hata dağılımı	49
Şekil 4.3. Trainlm eğitim, test ve doğrulama verilerinin başarımlarındaki değişim.....	50
Şekil 4.4. Trainlm ÇKYSA tahmin ve gerçek değere göre grafiği.....	52
Şekil 4.5. ÇKYSA trainscg 15 nöronlu tahmin sonuçları.....	54
Şekil 4.6. Trainscg hata dağılımı	55
Şekil 4.7. Trainscg Eğitim, test ve doğrulama verilerinin başarımlarındaki değişim.....	56
Şekil 4.8. Trainscg ÇKYSA tahmin ve gerçek değere göre grafiği.....	58
Şekil 4.9. ÇKYSA trainbr 10 nöronlu tahmin sonuçları.....	60
Şekil 4.10. Trainbr hata dağılımı	61
Şekil 4.11. Trainbr eğitim, test ve doğrulama verilerinin başarımlarındaki değişim	61
Şekil 4.12. Trainbr ÇKYSA tahmin ve gerçek değere göre grafiği.....	64
Şekil 4.13. ANFIS 2-2-2 modeli için uygulanan eğitim verilerinin yanıtları	66
Şekil 4.14. ANFIS 2-2-2 modeli için uygulanan test verilerinin yanıtları.....	66
Şekil 4.15. ANFIS 2-2-2 modeli için uygulanan kontrol verilerinin yanıtları.....	67

Şekil 4.16. ANFIS 2-2-2 modeli ağ yapısı.....	68
Şekil 4.17. ANFIS 2-2-2 modeli için oluşturulan grafiği	68
Şekil 4.18. ANFIS 2-2-2 modeli eğitim hatası grafiği.....	69
Şekil 4.19. ANFIS 2-2-2 modeli sonuçlara bağlı gerçek ve tahmin grafiği	70
Şekil 4.20. ANFIS 3-3-3 modeli için uygulanan eğitim verilerinin yanıtları	70
Şekil 4.21. ANFIS 3-3-3 modeli için uygulanan test verilerinin yanıtları.....	71
Şekil 4.22. ANFIS 3-3-3 modeli için uygulanan kontrol verilerinin yanıtları.....	71
Şekil 4.23. ANFIS 3-3-3 modeli ağ yapısı.....	72
Şekil 4.24. ANFIS 3-3-3 modeli için oluşturulan grafiği	73
Şekil 4.25. ANFIS 3-3-3 modeli Eğitim hatası grafiği	73
Şekil 4.26. ANFIS 3-3-3 modeli sonuçlara bağlı gerçek ve tahmin grafiği	74
Şekil 4.27. ANFIS 4-4-4 modeli için uygulanan eğitim verilerinin yanıtları	75
Şekil 4.28. ANFIS 4-4-4 modeli için uygulanan test verilerinin yanıtları.....	75
Şekil 4.29. ANFIS 4-4-4 modeli için uygulanan kontrol verilerinin yanıtları.....	76
Şekil 4.30. ANFIS 4-4-4 modeli ağ yapısı grafiği	77
Şekil 4.31. ANFIS 4-4-4 modeli için oluşturulan grafiği	78
Şekil 4.32. ANFIS 4-4-4 modeli Eğitim hatası grafiği	78
Şekil 4.33. ANFIS 4-4-4 modeli sonuçlara bağlı gerçek ve tahmin grafiği	80

ÇİZELGELER DİZİNİ

Çizelge 2.1. Yıllara göre enerji kaynaklarının üretim kapasiteleri (Teiaş 2023).....	25
Çizelge 2.2. Türkiye'nin kurulu gücü (Teiaş 2023).....	26
Çizelge 2.3. Türkiye enerji kaynakları 2012-2022 kurulu gücü (Teiaş 2023).....	26
Çizelge 2.4. Ardahan GES kapasiteleri (AFAD)	30
Çizelge 4.1. Girdi listesi.....	46
Çizelge 4.2. ÇKYSA trainlm modelinin, çeşitli öğrenme algoritmaları ve farklı gizli katman nöron sayıları altında elde edilen başarı sonuçları.	51
Çizelge 4.3. ÇKYSA trainlm uygulamasından elde edilen değerler	53
Çizelge 4.4. ÇKYSA trainscg modelinin, çeşitli öğrenme algoritmaları ve farklı gizli katman nöron sayıları altında elde edilen başarı sonuçları.	57
Çizelge 4.5. ÇKYSA trainscg uygulamasından elde edilen değerler	59
Çizelge 4.6. ÇKYSA trainbr modelinin, çeşitli öğrenme algoritmaları ve farklı gizli katman nöron sayıları altında elde edilen başarı sonuçları.	63
Çizelge 4.7. ÇKYSA trainbr uygulamasından elde edilen değerler	65
Çizelge 4.8. ANFİS 2-2-2 yapıdaki üyelik fonksiyonları ile gerçekleştirilen denemelerden elde edilen başarı verileri.	69
Çizelge 4.9. ANFİS 3-3-3 yapıdaki üyelik fonksiyonları ile gerçekleştirilen denemelerden elde edilen başarı verileri.	74
Çizelge 4.10. 4-4-4 yapıdaki üyelik fonksiyonları ile gerçekleştirilen denemelerden elde edilen başarı verileri.	79
Çizelge 4.11. ANFİS ve ÇKYSA hata oranlarına göre karşılaştırılması.....	80
Çizelge 4.12. 2022-2023 yılları üretim karşılaştırması.....	83

1. GİRİŞ

Elektrik enerjisi kullan alanların artması ile birlikte talep her gün artmakta, teknolojiyle birlikte vazgeçilmez konuma gelmiştir. Kurulu olan enerji santrallerinin büyük bir kısmı fosil yakıtlar kullanarak enerji üretmektedir; ancak rezerv açısından bu kaynaklar sınırlıdır ve küresel düzeyde coğrafi dağılımları ülkeler arasında farklılık göstermektedir. Ülkemizdeki, fosil kaynak rezervleri oldukça az bir seviyede bulunmakta olup, ihtiyacının büyük kısmını ithal etmektedir. Bu ithal edilen fosil kaynakların çoğu elektrik enerjisi üretiminde kullanılmaktadır. Bu kaynaklar için önem verilmesinin ana unsurlularından biri enerjinin güvenliği açısından ülkenin tehdit durumu olduğunun bir göstermektedir. Ayrıca, bu fosil kaynaklar kullanımı açısından çevreye zarar vererek sorunlara yol açmaktadır; içerik olarak karbon oluşumlu olduklarından, yanma başladığında çevreye karbon gazları salınarak kirlilik oluşturmaları.

Dünya atmosferinin troposfer katmanında, sera gazları yer almaktadır ve katmanın oluşturan organik bir süreçtir. Ancak, fosil kaynakların artan kullanımıyla bu katmandaki sera gazlarının oranı artmakta, bu da dünyanın daha fazla ısınmasına neden olmaktadır. Bu durum iklim değişikliklerini ve şiddetli meteorolojik olayları tetiklemektedir. Örnek verecek olursak, ülkemiz bir kaç yıldır hortum olaylarının arttığı gözlenmektedir. Sera gazındaki artış etkisiyle küresel ısınma, bazı bölgelerde kuraklık gibi sorunlara neden olurken, diğer bölgelerde aşırı yağışlar ve heyelan gibi farklı doğal afetlere yol açacaktır.

Yenilenebilir enerji kaynakları, enerjinin talebi konusunda bir artış görülmektedir. Bunun için yeterli bir seviyede yetebilmek bu kaynaklar sonucunda ortaya çıkan gaz emisyonunu azaltmak amacıyla ön plana çıkmıştır. Kyoto Protokolü ve Avrupa Birliği politikalarında değişiklikler yapılmıştır. Ülkelerin enerjinin korunumu açısından düzenlemelere gitmiş, bunun yenilenebilir enerjinin kullanımı olduğu belirlemiştir. Teknolojinin gelişmesi bu kaynaklara hidrolik enerji, güneş enerjisi, rüzgâr enerjisi, biyokütle enerjisi, jeotermal enerji ve dalga enerjisi örnek olarak verilebilir.

Bu enerji santrallerinin artmasıyla birlikte akıllı şebekelerin önemi günümüzde daha da artmıştır. Şebeke, Kullanılan enterkonnekte sistemlerden ayrıca, içinde

1. GİRİŞ

bulundurduğu sensörler kullanılarak üretilen enerjinin, iletilmesi ve dağıtılması kullanıcılar tarafından görülebilmesi sağlamaktadır. Oluşacak durumlara karşı öngörülen işlemler hızla gerçekleştirilir ve bu sistem güvenilirliği artırılır. Yurdumuzda ve küresel çoğu ülkelerde yatırımlar ve planlamalar, şebekelerin geliştirilmesine odaklanmıştır.

Ülkemizde, yenilenebilir enerji kaynaklarına olan ilgi giderek talep çoğalmaktadır. Ülkemizin kurulu gücü oldukça büyük bir kısmı olan 52.393,1 MW'lık yenilenebilir enerjinin sağladığı kaynaklar olup enerji üretimini bu santrallardan oluşmaktadır. Kurulu gücün çoğunluğu yani, 31.571,5 MW'lık hidrolik enerji üretimine yapmaktadır. Hidrolik enerjinin kullanımının yanı sıra güneş enerjisinin kullanımı takip ederken onun arkasından rüzgâr enerjisi gelmektedir. Yurdumuz, yenilenebilir enerjinin talebi açısından oldukça çeşitli ve kuvvetlidir. Bu kaynaklara talebin artması kullanılan fosil yakıtların ithalatını azaltmaya yardımcı olabilir.

Ülkemizde, özellikle güneş enerjisi yatırımlarıyla popülerlik kazanmaktadır. Ülkemizin konumu, güneş enerjisinden etkin bir şekilde yararlanmaya müsaittir. Sıralayacak olursak Güneydoğu Anadolu'nun sonrasında Akdeniz'in arkasından Doğu Anadolu'nun ve İç Anadolu bölgelerinin, güneş santralleri açısından oldukça uygun koşullara sahiptir.

Yenilenebilir enerji kaynaklarının mevcut entegre sisteme bağlanmasıyla çıkan sorun, meteorolojinin ve çevrenin yarattığı etkiler sonucunda enerji elde edilmesi doğrudan etkilenmektedir. Dünyamıza güneşten gelen radyasyonunun, diğer bir değişimle güneş ışınımının, Farklı alanda değişiklik gösterir. Doğal koşulların etkisi altında kalan santrallerin üretiminde elde edilecek değerleri görülmesi önem arz etmektedir.

Ülkemizin ve diğer ülkelerin enerji tüketimi noktasında talep her geçen gün artmakta bu artan tüketimin büyük bir çoğunluğu fosil yakıtlar tarafında karşılanmaktadır. Fosil yakıtlar gün geçtikçe azalması, karbon bazlı yakıtlar olması ve enerji tüketimi her geçen gün artması sonucunda yeni enerji kaynaklarına talebin artmasına neden olmuştur. Fosil yakıtlara nazaran daha ekonomik ve doğa dostu olan bu enerji kaynakları mevcut kullanım ve taleplere göre önümüzdeki yüz yıl içerisinde çok önemli noktada bulunup

1. GİRİŞ

yeni araçlarında elektrik enerjisi ile çalışır vaziyette geçmesi taşıma, ısınma dâhil olmak üzere elektrik enerjisinin bütün hayatımız saracak gibi görünmektedir.

Bu bağlamda Göle Belediyesi GES tesisinin meteorolojik veriler ile tahmin edilmesi ve Ardahan ilinin sıcaklığının ve kış şartlarının ılımanlaşması şehrin GES üzerine çalışılması gerektiğine dair veriler sunmaktadır. Yatırımcı şehir de ekonomik katkıda bulunması tesis sayısının artması fosil yakıtların azalması ve ülke dışına çıkan döviz ülke içinde kalması ekonomik olarak fayda sağlamaktadır. Toparlayacak olursak ilçe, il, ülke adına bir katma değer olup nüfus sayısı Türkiye'nin son 3 ili arasında yer alan ilimizdeki kullanılabilecek çok fazla alanının değerlendirilmesi gerekmektedir.



2. KAYNAK ÖZETLERİ

2.1. Literatür Özeti

Enerji, tarih boyunca yaşam için vazgeçilmez bir unsur olduğunu göstermektedir. Yenilenebilir enerjinin ve buna alternatif olan enerjinin kaynakları olan başta enerji sistemi güneş santrallerinin kurulması ve kullanılması artmaktadır. Literatür olarak güneş enerji sistemleri çok fazla çalışma bulunmaktadır. Çalışmaların genelinde güneş enerji sistemlerden ne kadar yüksek verim elde etmek amacıyla geliştirilen sistemlerin, programların üzerinde durulmuştur.

Yakın zamanda yapılan çalışmalar, Yapay Sinir Ağları'nın birçok alanda tahmin yapmak için kullanıldığını göstermektedir. Gelecekteki tahminler için YSA'nın en belirleyici alanların başında enerji gelmektedir. Yakın zamanda elde edilen araştırmalar, YSA'nın enerji üretimi, tüketimi ayrıca bu faktörlere tesir eden unsurların varsayımında belirgin bir şekilde kullanılabileceğini ortaya koymuştur. Bu alandaki bazı çalışmalar aşağıda listelenmiştir.

Yeşilkaya tarafından gerçekleştirilen incelemede, güneş pillerinin güneşe göre konum denetiminin bir mikroişlemci ile tasarımı ve uygulanması üzerinde çalışmalar yapılmıştır. Bu çalışma kapsamında, güneş panellerinin gün boyu maksimum güç üretimi sağlamak amacıyla Güneş'i takip etmeleri için elektronik bir modül geliştirilmiştir (Yeşilkaya 1998).

Bachtı, Fas bölgesinde gerçekleştirilen bir güneş enerjisi sistemi çalışmasında, güneş paneli destekli bir su pompalama sisteminin etkin bir şekilde çalışabilmesi için işletme koşulları üzerinde incelemeler yapmıştır. Bu çalışmada, iki fotovoltaiik panel kullanılarak maksimum güç noktasının belirlenmesi ve akım paylaşımının analiz edilmesi işlemleri gerçekleştirilmiştir (Bachtı 2002).

Bu çalışmada, kurulu bir uzaktan izleme ve kayıt sistemi kullanılmış ve hava olaylarındaki değişimlerin izlenmesi ile çeşitli iklimsel uygulamaların yapılmasında potansiyel faydalarına dikkat çekilmiştir. Carlson ve arkadaşları ise, geliştirdikleri bir

güneş pili sisteminde uzaktan izleme programını kullanarak maksimum güç gereksinimlerine göre uygun yük seçimlerinin yapılması konusunda elde ettikleri sonuçları sunmuşlardır (Carlson et al. 2002).

Isparta'nın güneş enerjisinden yararlanma oranı incelenmiştir. Bu çalışma kapsamında, bir güneş pili sistemi ile çalışan bir düzenek kurulmuş ve belirli iklim koşullarında testler gerçekleştirilmiştir. Örnek düzenek, bir adet güneş pili, regülatör devresi, akü, DC-AC evirici devresi, trafo, yük ve ölçüm elemanlarından oluşmaktadır. Deneyler, Keçiborlu Meslek Yüksekokulu'nda gerçekleştirilmiş olup, güneş pili tam güney yönüne ve 37° eğime yerleştirilmiştir. Ancak, bu çalışmada güneş pillerinin güneşi takip sistemi olmadan, sistemdeki bileşenlerin (evirici, akü vb.) verimlilikleri kaydedilmiştir (Kutlu 2002).

Çelebi'nin "Bir Binanın Dış Kabuğunda PV Hücrelerinin Kullanım İlkeleri" başlıklı çalışmasında, fotovoltaik (PV) düzeneğin kullanımının önemi vurgulanarak, bu tür sistemlerin kısa tarihçesi sunulmuştur. PV modüllerin genel yapısı, çeşitleri ve temel özellikleri incelenmiş, ayrıca bu sistemlerin binanın dış kabuğunda kullanılmasının tasarım üzerinde etkileyebileceği olası faktörler üzerinde durulmuştur. Çalışmada, bir binada dış kabuğun tamamında fotovoltaik panellerin uygulanabilirliği, şekilsel farklılıklara göre sınıflandırılmış ve çeşitli görseller aracılığıyla açıklanmıştır (Çelebi 2002).

Yıldız, "PV Modüllerin Meskenlerde Kullanımı ve PVSYST 3.21 Programı ile Bir Evin Simülasyonu" başlıklı yüksek lisans tez çalışmasında, enerji harcamalarında önemli bir paya sahip olan meskenlerde güneş enerjisinden yararlanma potansiyelini incelemiştir. Güneş enerjisinden etkin bir şekilde faydalanmayı sağlayan fotovoltaik (PV) sistemlerin binalarda kullanılabilirliği araştırılmış ve PV sistemlerinin projelendirilmesinde kullanılan simülasyon yöntemleri incelenmiştir. Bu simülasyonlar arasından bir tanesi seçilerek, Ankara Armada AVM'nin modellenmesi gerçekleştirilmiş ve elde edilen veriler üzerinde analizler yapılmıştır (Yıldız 2003).

Elektrik enerjisi talep tahmini gibi gelecekteki zaman aralıkları için Yapay Sinir Ağları'nın kullanıldığı bir alanın olduğu bilinmektedir. Geleceğin enerji tahminlerine dair

birçok çalışma, Yapay Sinir Ağları'nın geleneksel yöntemlere kıyasla doğru çıktılar elde edilmiştir (Hamzaçebi ve Kutay 2004).

Yona ve arkadaşları, fotovoltaik sistemlerin güç çıkışının mümkün olan en doğru şekilde tahmin edilmesinin, karmaşık hesaplamalar ve matematiksel modellere gerek duyulmadan gerçekleştirilebileceğini göstermişlerdir. Bu çalışmada, bir gün öncesine ait 24 saatlik güneşlenme süresinin tahmin edilebilmesi için Yapay Sinir Ağları (YSA) kullanılmış ve şu modeller seçilmiştir: İleri Beslemeli Sinir Ağı (FFNN), Temel Radyal Fonksiyonlu Sinir Ağı (RBFNN) ve Tekrarlayan Sinir Ağı (RNN). Seçilen modeller arasında en başarılı sonuçların RBFNN ve RNN tarafından verildiği gözlemlenmiştir. Çalışmanın sonuç kısmında, fotovoltaik sistemlerde etkin bir tahmin aracı olarak YSA modellerinin kullanılabileceği vurgulanmıştır (Yona et al. 2007).

Yapılan çalışmada, fotovoltaik sistemlerde karşılaşılan problemleri incelemek için Yapay Zeka Teknikleri kullanılmıştır. Fotovoltaik sistemlerin kurulumu, boyutlandırılması, simülasyonu ve kontrolü ile ilgili problemler üzerinde araştırmalar yapılmıştır. Ayrıca, meteorolojik verilerin tahmin edilmesi ve modellenmesi konusunda da çalışmalar yapılmıştır. Bu çalışmaların sonuçlarından elde edilen çıktılarına bakılarak, DSP, Mikrodenetleyici ve FPGA donanım odaklı Yapay Zeka yaklaşımlarının kullanılması, Akıllı FV sistemlerinin kontrol, izleme, teşhis ve gözetim işlevlerini geliştirmek için promising (umut vaat eden) bir yöntem olarak önerilmiştir (Mellit and Kalogirou 2008).

Lorenz ve arkadaşları, fotovoltaik sistemlerden elde edilen güç tahminlerinde güneş radyasyonunun etkisini incelemişlerdir. Gerçekleştirdikleri çalışmada, Avrupa Orta Vadeli Hava Durumu Tahminleri Merkezi (ECMWF) tarafından sağlanan üç günlük tahmin verilerine dayalı olarak bölgesel fotovoltaik enerji çıktılarının tahminine yönelik bir yöntem geliştirmişlerdir. Ayrıca, Almanya için bölgesel bazda ve ülke genelinde kök ortalama kare hata (RMSE) değerini hesaplamışlardır. Bu araştırmada, fotovoltaik güç tahminlerinin doğruluğunu değerlendirmişlerdir (Lorenz et al. 2009).

Isparta iline ait rüzgâr hızlarını ANFIS ve YSA yöntemleriyle tahmin etmiştir. Yapılan tahminde YSA yöntemi kullanılmış ve en iyi sonucun LM12 algoritmasıyla elde

edildiği tespit edilmiştir, bu tahminde Tan-sig fonksiyonunun kullanılması tercih edilmiştir. Çalışmanın sonucunda ANFIS yöntemiyle elde edilen R^2 değerinin YSA ile elde edilen değere kıyasla daha yüksek olduğu gözlenmiştir (Özcan vd 2013).

Erzincan ilinin güneş enerjisi elektrik üretimi potansiyeli incelenmiştir. Bu incelemede Meteoroloji Genel Müdürlüğünden alınan veriler, Enerji ve Tabii Kaynaklar Bakanlığından alınan GEPA verileri, Avrupa Komisyonu Enerji ve Ulaştırma Enstitüsü PVGIS verileri ve Avrupa Komisyonu Enerji ve Ulaştırma Enstitüsü CM-SAF PVGIS veri kaynağından güncel veriler kullanılmıştır. Erzincan ilinin güneş enerjisi potansiyeli, toplam kurulu PV sistem kapasitesi bakımından Almanya ile karşılaştırılarak değerlendirilmiştir. Karşılaştırma sonucunda, Erzincan ilinin güneş enerji potansiyelinin Almanya'dan yaklaşık %50 daha fazla olduğu gösterilmiştir. Bu veriler ışığında, Türkiye genelinde güneş enerji potansiyelinin yüksek olduğu ve potansiyel olarak enerjinin üretimindeki değerlendirme için devlet aracılığı ile teşviklerin artırılması gerektiği, öte yandan insanları bilgilendirici çalışmalar yapılması gerektiği belirtilmiştir (Çakmak ve Atlas 2016).

Çiftçi (2016) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, tek kristalli ve çok kristalli güneş panellerini karşılaştırarak güç analizi yapmıştır. Bu analizler sonucunda, tek kristalli güneş panelinin verimliliğinin, çok kristalli güneş paneline göre daha yüksek olduğu tespit edilmiştir. Ancak, çok kristalli güneş panellerinin daha düşük maliyetli olması nedeniyle amortisman süresinin daha kısa olduğu sonucuna ulaşılmıştır (Çiftçi 2016).

Coşkun ve arkadaşları, yapay sinir ağları (YSA) kullanarak bir fotovoltaiik (FV) panelin yüzey sıcaklığını tahmin etmişlerdir. YSA'yı eğitmek için dış sıcaklık, güneş radyasyonu ve rüzgâr hızı gibi giriş parametreleri kullanılırken, çıkış olarak yüzey sıcaklığı alınmıştır. Bu çalışmada, FV panel yüzey sıcaklığının tahmini amacıyla üç farklı algoritma türü kullanılmış ve sonuçlar karşılaştırılmıştır. En iyi tahmin sonuçları, Levenberg-Marquardt (LM) algoritması ile elde edilmiştir. Yapay sinir ağlarının, FV yüzey sıcaklığını tahmin etmede konvansiyonel ilişki modellerine kıyasla daha başarılı olduğu gözlemlenmiş ve bu çalışma, FV yüzey sıcaklığının tahmin edilmesinde yapay sinir ağlarının etkili bir şekilde kullanılabileceğini ortaya koymuştur (Coşkun vd 2016).

Kastamonu iline ait 2009 ile 2016 yılları arasında ölçülen aylık ortalama nispi nem, aylık ortalama sıcaklık, aylık açık gün sayısı, aylık ortalama hava basıncı, aylık ortalama rüzgâr hızı, aylık toplam güneşlenme süresi ve aylık toplam güneş ışınım şiddeti verilerinden yararlanarak belirtmiştir. Yapay Sinir Ağları yönteminin güneş radyasyon değerlerinin tahmininde başarıyla kullanılabileceği görülmüştür (Güleç vd 2017).

Cebeci (2017) yılında hazırlamış olduğu uzmanlık tezinde, Dünya ve Türkiye'nin güneş enerjisinden elektrik üretim potansiyelini değerlendirerek, güneş enerjisi santrali (GES) yatırımlarının amortisman sürelerini hesaplamıştır. Çalışma sonucunda, güneş enerjisinden üretilen elektrik enerjisinin maliyetinin, teşviklerle birlikte zamanla azaldığı bulgusuna ulaşmıştır (Cebeci 2017).

Sağlam (2018) yılında yazmış olduğu tez çalışmasında, güneş enerji sistemlerinin kurulum aşamalarını ve mevcut santrallerin verimlilik analizlerini gerçekleştirmiştir. Yapmış olduğu simülasyonlar sonucunda, kurulum öncesinde simülasyonlar ile tahmini üretim değerlerinin hesaplanmasının ve meteorolojik verilerin dikkate alınmasının önem taşıdığı sonucuna varmıştır (Sağlam 2018).

Özçelik (2018) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, santralin kurulacağı bölge için Türkiye enerji potansiyeli haritasına dayanarak bir planlama yapılması gerektiğini vurgulamış ve yatırım için uygun saha belirlendikten sonra teknik ilerleme adımlarını incelemiştir. Çalışmasında, sistem tasarımının belirlenmesi, panellerin eğim açısı, invertör, panel üreticisinin yıllık üretime etkisi, kablo kesiti ve kablo uzunluğu gibi faktörlerin incelenmesine odaklanmıştır. Bu incelemeler sonucunda, panellerin eğim açısının 30 derece olarak belirlenmesi, PV dizi/evirici oranının 1.1-1.2 aralığında olması, büyük kablo kesitlerinin kullanılması, kısa kablo uzunlukları ve coğrafi koşullara göre uygun panel seçiminin yapılarak tasarlanan sistemlerin daha verimli olacağı sonucuna ulaşmıştır (Özçelik 2018).

Şahin (2019) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, 200 kW gücündeki bir güneş enerji santralinin farklı iklim koşullarındaki kurulu sistemden ölçülen verilerini karşılaştırmıştır. Çalışma sonucunda, güneş panellerinin güneşli, serin

ve rüzgârlı hava koşullarında daha yüksek güç üretimi sağladığı belirlenmiştir (Şahin 2019).

Keskin (2019) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, Niğde ilinde bulunan bir güneş enerji santrali için modelleme yaparak, enerji üretimi, kayıp değerleri ve sistem performans parametrelerini hesaplamıştır. Sistem performansındaki kayıpların, tozlanma, ısı kayıplar, invertör kayıpları gibi çeşitli faktörlerden kaynaklanabileceğini incelemiş ve kayıpların büyük bir kısmının modüllerin bozulma kaybindan kaynaklandığı sonucuna ulaşmıştır (Keskin 2019).

Ayran (2019) yılında gerçekleştirdiği yüksek lisans tez çalışmasında Kütahya'da belirlemiş olduğu arazi tipi güneş enerji santralinin benzetim programı ile gerçek değerleri arasındaki oransal farkı hesaplamıştır. İklim şartlarına göre 25 derecelik açı ile konumlandırılan Kadmiyum Tellürid yapıda bulunan ince film panellerin diğer PV panellere göre daha yüksek verime sahip olduğunu bölgedeki aşırı sıcaklık kaynaklı merkezi invertörlerde kabin sıcaklığının korunamaması sonucu devre dışı kaldığı ve bu tür bölgelerde dizi invertör kullanılması gerektiği sonucuna ulaşmıştır (Ayran 2019).

Kılınç (2019) yılında gerçekleştirdiği tez çalışmasında, İzmir için 500 kW'lık bir fotovoltaik sistemin yüzey alanını hesaplamıştır. Hesaplamalarda, panellerin yatayla yaptığı eğim açısını sabit tutmak yerine, yaz ve kış aylarında farklı eğim açılarıyla kurulum yapılacağı varsayılmıştır. Çalışmada, sistemin hangi aylarda ve hangi koşullarda daha fazla enerji üreteceği veya daha fazla güneş ışınımından faydalanabileceği belirlenmiştir. Ayrıca, monokristal ve polikristal fotovoltaik paneller arasındaki %4'lük verim farkı ile panel alanında %23,6 oranında önemli bir kazanç farkı olduğu ifade edilmiştir (Kılınç 2019).

Bir güneş enerjisi santralının üretim değerlerini meteorolojinin bağlı olarak Yapay Sinir Ağı modeli ile tahmin etmiştir. Gerçekte olması gereken çıkış değerleri ile Yapay Sinir Ağı tarafından tahmin edilen çıkış değerlerinin karşılaştırılması sonucunda, test, eğitim ve doğrulama verileriyle birlikte tüm veri sonuçlarının regresyon değerlerinin 1'e yakın olduğu hesaplanmıştır (Geçmez ve Genç 2020).

Kılıcı (2020) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, PVSYST simülasyon programı kullanarak, tek yüzeye sahip panellerle sabit, mevsimsel açısı değişebilen, tek eksenli güneş takip sistemli, çift yüzeyli sabit sistem ve çift yüzeyli güneş takip sistemlerinin performans analizlerini yapmıştır. Bu analizler sonucunda, maksimum verime %90,48 ile çift yüzeye sahip paneller kullanarak tek eksenli güneş takip sisteminde ulaşılmıştır (Kılıcı 2020).

Tunçgövide (2020) yılında yazmış olduğu tez çalışmasında, İzmir ilinde uygun panel seçimi ve yatırımın doğru bir şekilde yapılabilmesi için gerekli değişkenler kullanılarak verimlilik hesaplamaları ve yatırım maliyeti analizi gerçekleştirmiştir. Yapılan analizler sonucunda, panellerin 25 yıllık ömrü boyunca elde edilecek kazanımlar hesaplanmıştır. Bu hesaplamalar neticesinde, monokristal yapıli panellere sahip güneş enerji santrallerinin, verimlilik ve finansal açıdan polikristal yapıli santrallere göre daha avantajlı olduğu sonucuna ulaşılmıştır (Tunçgövide 2020).

Öztürk (2021) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, simülasyon programları ile elde edilen tahminleri gerçek üretim verileri ile karşılaştırmış ve simülasyon programının, gerçek üretim verisinden %3,74 oranında daha yüksek sonuçlar verdiğini ortaya koymuştur. Bu farkın, panellerde oluşabilecek kirlilik, kış koşulları ve simülasyon programında yer almayan doğru akım kablosu, alternatif akım kablosu, saha toplama panoları ve trafolar gibi unsurlardan kaynaklandığını ifade etmiştir (Öztürk 2021).

Kınalı (2019) yılında gerçekleştirdiği yüksek lisans tez çalışmasında, güç kapasitesi farklı güneş enerji santrallerini çeşitli simülasyon programları kullanarak analiz etmiş ve kapasite faktörü, performans oranı, final verimi, referans verimi ve yıllık enerji üretimi gibi parametreleri incelemiştir. Parametre kıyaslamasında, simülasyon programlarının doğruluğunun meteorolojik veri tabanından etkilendiğini ve hata payının PVSOL programında en düşük seviyeye indiğini belirlemiştir (Kınalı 2019).

Çınaroğlu (2021) yılında yayınlamış oldukları makale de Kilis ilinde bulunan üç adet güneş enerji santralinin aynı özelliklerde simülasyon programlarında çizimleri ve simülasyonları yapılmıştır. Çalışmalar sonucunda santrallerin yıllık üretim değerleri

arasında değişiklikler gözlemlendiğini belirtmişlerdir. Panel verimlerinin her yıl azaldığı bundan dolayı da üretim miktarının düştüğü belirtilmektedir. Bulutsuz ve güneşli günlerin fazla olduğu aylarda üretim artmaktadır. Başka bir durumda ise sıcak olan yaz aylarında sıcaklığın etkisi ile kayıpların oluşacağı sonucunda ulaşmışlardır (Çınaroğlu 2021).

2.2. Güneş Enerjisi Tarihsel Gelişimi

Güneş enerjisi, insanlık tarihinin başlangıcından beri kullanılan ve giderek önem kazanan” bir enerji kaynağı olmuştur. İnsanlar, güneşin ışığından ve ısısından faydalanarak tarım, ısınma ve ışık sağlama gibi temel ihtiyaçlarını karşılamışlardır. Ancak, güneş enerjisinin modern anlamda kullanımı ve teknolojik uygulamaları tarihsel olarak son yüzyıla kadar uzanmaktadır.

Güneş enerjisinin modern kullanımı, 19. yüzyılın sonlarına doğru başlamıştır. 1839'da Alexandre Edmond Becquerel, güneş ışığının bir elektrot aracılığıyla suyu elektroliz ederek hidrojen ve oksijen üretebileceğini keşfetti. Bu keşif, fotovoltaiik etki olarak bilinen güneş ışığının doğrudan elektrik enerjisine dönüşümünü açıklamıştır. Becquerel'in fotovoltaiik enerjiyi keşfetmesinden bir süre sonra, 1893 yılında, ilk kez Charles Fritts selenyum plakalarını, ince bir altın tabakası ile kapladı. Böylece ilk güneş paneli Charles Fritts tarafından yapılmıştır.

20. yüzyılın başlarında, güneş enerjisi toplama ve depolama teknolojileri geliştirilmeye başlandı. Bell Laboratuvarlarında çalışan Amerikalı mucit Russel Ohl, 1941'de dünyanın ilk silikon kaynaklı güneş pilini bularak, patentini aldı. Ohl'un icadı aynı şirket tarafından 1954'de silikon kullanımı ile yeni bir güneş panelinin üretimine yol açtı. 1950'lerde, Güneş enerjisi kullanılarak elektrik üretmek için fotovoltaiik hücrelerin geliştirilmesi başladı. NASA, uzay araçlarında güneş panelleri kullanarak uzun süreli enerji sağlama konusunda öncü oldu.

1970'lerde, petrol kriziyle birlikte yenilenebilir enerji kaynaklarına olan ilgi arttı. Bu dönemde, fotovoltaiik hücrelerin verimliliği artırıldı ve ticari olarak kullanılabilir hale geldi. Aynı zamanda, güneş enerjisi kolektörleriyle ısınma ve sıcak su sağlama sistemleri popülerlik kazandı.

2000'lerde, çevresel kaygılar ve enerji fiyatlarındaki artışlar güneş enerjisinin daha da önemli hale gelmesine neden oldu. Yenilenebilir enerji politikaları ve teşviklerin artmasıyla birlikte, güneş enerjisi santralleri dünya genelinde yaygınlaşmaya başladı. Teknolojik ilerlemeler ve maliyetlerin düşmesiyle birlikte, fotovoltaik sistemler evler, işletmeler ve endüstriyel tesisler için ekonomik bir seçenek haline geldi.

Bugün, güneş enerjisi dünyanın dört bir yanında yaygın olarak kullanılmaktadır. Güneş enerjisinin, doğal, sürdürülebilir yani yenilenebilir enerji kaynağının gelecek nesillere bırakılacak önemli bir miras olarak görülmektedir. Teknolojik yenilikler ve politika destekleri ile birlikte, güneş enerjisinin önemi ve kullanımı giderek artmaktadır.

2.3. Güneş Enerji Santralleri ve Çalışma Prensibi

Güneş enerjisi, günümüzde giderek daha fazla popülerlik kazanan bir enerji kaynağıdır. Güneş enerjisi santralleri, güneşten gelen ışığı elektriğe dönüştüren sistemlerdir. Çalışma prensibine bakarsak Güneş enerjisi santralleri, güneş ışığını elektriğe dönüştüren fotovoltaik (PV) hücreler veya güneş enerjisi termal kolektörler aracılığıyla çalışır. İki ana türü vardır:

Fotovoltaik (PV) Sistemler : PV sistemlerinde, güneş ışığı doğrudan fotovoltaik hücreler tarafından yakalanır ve doğru akım (DC) elektriğe dönüştürülür. Bu elektrik, inverterler aracılığıyla alternatif akıma (AC) dönüştürülerek ev veya işyerlerinde kullanılabilir elektrik enerjisi elde edilir.

Güneş Enerjisi Termal Santralleri: Bu tür santraller, güneş ışığını kullanarak suyu veya başka bir akışkanı ısıtan aynalar veya lensler kullanır. Isınan akışkan, buhar üretir ve bu buhar türbinleri döndürerek elektrik enerjisi üretmek için bir jeneratörü çalıştırır. Tekil fotovoltaik hücreler veya paneller aracılığıyla güneş ışığını yakalarlar. Büyük ölçekli PV santralleri genellikle geniş arazilere yayılmıştır ve onlarca hatta yüzlerce megavat elektrik üretebilirler.

Konsantre Güneş Enerjisi (CSP) Santralleri: Genellikle büyük boyutlu, merkezi bir termal kolektörü olan santrallerdir. Aynalar veya lensler, güneş ışığını bir noktaya

odaklar ve yüksek sıcaklıklara ulaşmak için kullanılır. Elde edilen ısı, buhar türbinlerini döndürmek için kullanılır ve elektrik üretilir. Parabolik oluklu kolektörler, kule odaklı sistemler ve dish-engine sistemleri gibi farklı CSP teknolojileri bulunmaktadır.

2.4. İşletme ve Bakım Stratejileri

Tabanlı bakım onarımın temel amacı, arıza nedeniyle bakım ve onarım gereksinimlerini minimize ertmektir ve genellikle koruma amaçlı bakım olarak adlandırılır. Önleyici bakımın planlanması, çeşitli faktörlere bağlı olarak gerçekleşir, bu faktörler arasında seçilen teknoloji, sistem çevresi ve sezonluk değişimler bulunur. Planmış bakımın genel olarak üretici önerileri ışığında planlanır, periyodik olarak ve cihaza garanti şartlarına uygun olarak gerçekleştirilir.


Fotovoltaik panellerin temizliği, sistem verimini önemli ölçüde etkileyen bir faktördür. Toplanan partiküller, ışınlarının hedeflenen hücreler gitmesi zorlandığından, panellerin kirlenmesi voltajın düşük olması ile farklı sorunlara yol açar. Oluşan durum, toz bulunan yerlerde %7'ye kadar, Ortadoğu'daki kum ile çöl koşullarının sıkça yaşandığı yerlerde ise %50'yi gören enerjinin kayıp olmasına sebep olabilir.

Fotovoltaik enerji santrallerinde en yaygın sistem kesintilerinin sebebi olarak bu arıza türü gösterilebilir. Mümkün olan en yüksek düzeyde verim elde etmek için inverter bakımı düzenli aralıklarla yapılmalıdır. Bu şekilde plansız bakım onarım maliyetleri azaltılabilir. Düzenli kontroller ile inverterlerin çalışması takip edilebilir ve gerektiğinde anında müdahale edilebilir. Bu ekipmanda aşırı ısınma, akım sorunları, düşük veya aşırı gerilim, yalıtım problemleri, fan arızaları gibi sorunlar ortaya çıkabilir. Düzenli kontroller sayesinde bu sorunlar tespit edilip uzmanlar tarafından giderilebilir (Savaş vd 2022).

2.5. Fotovoltaik Paneller


P-n eklem olarak adlandırılan bir yapı, p ve n tipi katkılanmış iki yarıiletkenin bir araya gelmesiyle oluşur. Elektronların iletim bandında fazla olan malzemelere n-tipi yarıiletken denir, yani atomun son yörüngesinde elektronun fazla olduğu

yarıiletkenlerdir. Atomların son yörüngesinde boşlukların fazla olduğu, elektron almaya istekli atomlardan oluşan malzemelere ise p-tipi yarıiletken denir.



Şekil 2.1. Fotovoltaik panel yapısı (Özdemir 2022)

N-tipi bölgede, güneşten gelen fotonlar fazla elektronları (iletime katılmaya hazır) koparıp boşlukları p-tipi bölgeye doğru hareket ettirir. Bu hareket, elektron-hole çiftlerinin oluşmasına neden olur. P ve n bölgelerinde elektronun az ya da çok olması, her iki tarafta da elektrik alanının oluşmasına neden olur. Oluşan bu elektrik alan sayesinde ayrılan elektron-boşluk çiftleri, fotovoltaik hücrenin kontak uçları arasında bir çıkış gücü oluşturur (Özdemir 2022).



Şekil 2.2. Fotovoltaik panel çalışma prensibi (Özdemir 2022)


Farklı işlevlere sahip katmanlardan oluşan bir güneş hücresi gözlemlenmektedir. Üretimde kullanılan malzemeye bağlı olarak fotovoltaik hücreler, sağlamlık açısından en üst katmanın cam ile kaplı olduğu şekilde tasarlanmaktadır. Sisteminin temelinde yer alan fotovoltaik Panelleri üç başlıkta sıralayabiliriz.

2.5.1. Monokristal silisyum hücreler

Monokristal hücreler, yüksek saflıkta silisyum içerdikleri için polikristal hücrelere göre daha verimlidirler, ancak silisyum üretimindeki zorluklar nedeniyle fiyatları daha yüksektir. Gün içindeki sıcaklık artışının verim üzerindeki etkisi polikristal hücrelere göre daha azdır ve yapı bakımından özelliklerini daha uzun süre koruyabilirler. Monokristal güneş panelleri, tek kristalli hücreler olarak da adlandırılır ve diğer panellerden koyu siyah renkleri ve sekizgen şekilde kesik kenarlarıyla daha kolay tanınır. Atomik yapısı gösterilen mono-Si malzemesi, silisyum fotovoltaik paneller arasında en yüksek verime ve güç kapasitesine sahiptir. Mono-Si panellerin verimlilikleri günümüzde %22 ile %27 arasındadır (Özdemir 2022).

Tabanlı tekil silisyum paneller, 25 yıl boyunca kullanım garantisi sunan panellerdir, ancak maliyet açısından diğer silisyum panellerine göre daha pahalıdır. Bunun temel nedeni, saf kristal yapıları ve özel olarak kesilmiş dört kenarı olan panellerin


üretim sürecidir. Bu özel kesim işlemi, önemli miktarda atık üretir ve dolayısıyla maliyeti artırır.



Şekil 2.3. Monokristal silisyum hücre yapısı (Özdemir 2022)

2.5.2. Polikristal silisyum hücreler


Polikristal güneş panelleri, saf silisyumdan üretilir. Polikristal paneller, tek bir silisyum kristali yerine farklı silisyum kristallerinin bir araya gelmesiyle oluşturulur ve bu da onları mono-Si panellerinden farklı kılar. Polikristal hücreler, monokristal hücreler gibi benzer üretim aşamalarından geçer; ancak monokristal hücrelere göre üretimleri daha kolay ve daha ucuzdur. İstenilen incelikteki saf silisyum, eritilerek kalıplara alınır, ardından özel tekniklerle kesilerek hücreler hazırlanır. Verimleri monokristal hücrelere kıyasla düşüktür, ancak maliyetlerinin düşük olması nedeniyle tercih edilirler. Ayrıca, günümüzde polikristal güneş panelleri %13 ila %20 arasında bir verimle çalışmaktadır.



Şekil 2.4. Polikristal silisyum hücre yapısı (Özdemir 2022)

2.5.3. Amorf silisyum hücreler

‘Amorf’, tam olarak ‘şekilsiz’ anlamına gelir ve yarıiletken silisyumun kristal olmayan bir formudur. Bu tür paneller, güneş ışığını yüksek bir emilim kapasitesine sahiptir, yani görünür spektrumda (380nm-740nm) enerji üretebilirler. İç mekanlarda, zayıf ışık altında tam güçte çalışma yeteneklerine sahiptirler; ayrıca hesap makineleri ve saatler gibi küçük elektronik cihazları şarj etmek için tercih edilirler, çünkü ucuz bir seçenektirler. Diğer silisyum fotovoltaik panellerle karşılaştırıldığında, en düşük verimliliğe sahip olması nedeniyle maksimum %13 verimlilik sağlar. Birim alan başına ürettikleri elektrik enerjisi diğer hücre tiplerine kıyasla daha az olsa da, sıcaklığa karşı dirençleri daha fazladır ve esnek yapısıyla kolay bir kurulumu sahiptir.



Şekil 2.5. Amorf silisyum hücre yapısı (Özdemir 2022)

2.6. Solar Eviriciler

Eviriciler, uygun anahtarlama dizisi kullanarak DC kaynağından kontrol edilebilen genlik, frekans ve faz açısı ile alternatif bir gerilim üreten güç elektroniği devreleridir. Solar İnverterler 3 ana başlık altında toplanır.



Şekil 2.6. Solar evirici

2.6.1. Off-Grid inverterler

Eviriciler, DC kaynağından uygun anahtarlama dizisi kullanarak genlik, frekans ve faz açısını kontrol edebilen, alternatif bir gerilim üreten güç elektroniği devreleridir. Bu sistemler, dağıtım şebekesinin olmadığı yerlerde sıklıkla kullanılır ve üretilen enerjinin depolandığı sistemlerde tercih edilir. Güneş panellerinden elde edilen elektrik, ya doğrudan AC'ye dönüştürülerek ya da akülerde depolanan DC enerjisi, inverterler aracılığıyla AC'ye dönüştürülerek enerji ihtiyacını karşılar (Kocakuşak 2018).

2.6.2. On-Grid inverterler

Dağıtım şebekesi olan sistemlerde de kullanılan eviriciler, panel oluşan DC elektrik direkt AC enerjiye dönüşümünü sağlar üretilen enerji, şebekeye anında aktarılır çünkü şebeke bağlantılıdır. Kullanım alanlarına göre iki tür evirici vardır. Merkezi inverterler, genellikle büyük güçleri olan lisanslı santrallerde tercih edilir. Saha ve çatı uygulamalarında ise dizi inverterler kullanılır. Dizi inverterlerin amacı, bir santrali belirli kısımlara ayırarak her bir parçanın bağımsız olarak enerji üretimini gerçekleştirmesine olanak tanımadır (Kocakuşak 2018).

2.6.3. Hibrit inverterler

Bu sistem, dağıtım şebekesine bağlı olarak çalışırken aynı zamanda batarya ve akü teknolojisinin ekstra avantajlarını sağlamak için birlikte kullanılır. Üretilen enerji, tüketimden fazla olduğunda akülerde veya bataryalarda enerji depolanırken, tüketim üretimden fazla olduğunda akülerden enerji kullanılır. Bu tür inverterlerde, ihtiyaç duyulmadığı sürece şebekeden elektrik çekilmez (Kocakuşak 2018).

2.7. Trafo

Solar güneş sistemlerinde üretilen enerji, inverterler vasıtasıyla kablolar aracılığıyla AG toplama panolarına iletilir ve buradan güç trafosuna aktarılır. Güneş enerji sistemlerinde kullanılan trafolar, dağıtım şirketlerinden alınan güç değerleri dikkate

alınarak yerleştirilir. Özellikle güneş trafoları, fabrikalarda üretildikleri yerlerde A+ sınıfı olarak üretilmektedir.



Şekil 2.7. Kabin tipi trafo köşk

2.8. Panel Taşıyıcı Sistemler

Güneş enerji sistemlerinde, panelin taşınmasını sağlayan ve santralin maliyetinin %10'unu oluşturan sabitleme sistemi bulunmaktadır. Bu sistem, kurulacak arazinin özelliklerine göre değişiklik gösterir. Eğer arazi kayalık bir yapıya sahipse, beton ayaklar kullanılırken, toprak zeminde ise çakma ayaklar tercih edilir. Güneş panelleri, bu sistem üzerine monte edilerek uygun azimut, eğim açıları ve aralık mesafelerine göre yerleştirilir. Tek veya çift ekseni olan GES takip şebekesi de tasarlanabilir. Güneş takip sistemleri, daha fazla ışınlam aldıkları için daha fazla enerji üretebilme yeteneğine sahiptirler. Güneş enerjisinden elde edilen elektrik miktarı, FV panelin üzerine düşen ışınlamın yoğunluğuna bağlıdır. Bu nedenle, FV panelinin konumu üretim açısından önemlidir. GES takibini sağlayan sistemler, gücün maksimum üretiminin ortaya

ıkmasında etkilidir ancak klasik baėlantılı sistemlere kıyasla daha maliyetlidirler (Saėlam 2022).



Şekil 2.8. Zemin tipi panel taşıyıcı sistem

2.9. Çift Yönlü Elektrik Sayacı


Çift yönlü elektrik sayacı üretimlerimizi ve tüketimlerimizi mahsuplaştırma amacı ile konulan dağıtım şirketince tedarik edilmektedir. Tüketilen enerjiyi 1.80 hanesinde yer alırken üretilen enerjiyi ise 2.80 hanesine kayıt eder. Aylık olarak bu veriler tedarik şirketi ve tesis sahibi arasında tutanağına bağlanır. Her üretim tesisinin ve elektrik üretim dağıtım noktasının birde yedek sayacı olur birinin bozulması halinde diğlerinden teyit edilerek sistem kontrol edilmiş olur.



Şekil 2.9. Çift yönlü sayaç

2.10. Türkiye'nin ve Dünya'nın Yenilenebilir Enerji Durumu

Enerjiyi elde ettiğimiz kaynakları arasında öneme sahip olan ve en büyük kaynak güneştir. Dünya yüzeyine her yıl düşen güneş ışınım enerjisi, yaklaşık olarak fosil yakıt rezervlerinin 160 katı kadardır. Ayrıca, bu enerji her bölgede koşulsuz olarak kullanılabilir ve bölgesel uygulamalarda oldukça elverişlidir. Bazı kaynaklara göre, güneş enerjisi fosil yakıtlardan ve hidroelektrik santrallerinden üretilen bir yıllık enerjinin 15.000 katı kadar daha fazla enerji üretme potansiyeline sahiptir (Yalçın 2019).




Şekil 2.10. Dünyanın güneş ışınımı (Yalçın 2019)

Dünyadaki yıllık enerji kullanımı ve tüm enerji kaynaklarının da belirtildiği enerji küp grafiği, yıllık güneş enerjisi miktarının büyüklüğünü vurgulamak için Şekil 2-10'de gösterilmiştir. Şekildeki en büyük küp, yüksek güneş ışınımını temsil etmektedir ve sarı renkle belirtilmiştir. Sol tarafta bulunan küpler, uranyum, petrol, doğal gaz ve kömür rezervlerini simgeler. Sağ alt köşedeki küp ise yıllık olarak dünyadaki enerji kullanımını gösterir. Sarı küp ile belirtilen güneş ışınımı, dünyamıza her gün düzenli olarak ulaşır. Bu nedenle, güneş enerjisi sürekli olarak kendini yenilediği için en büyük yenilenebilir enerji kaynağıdır (Yalçın 2019).

Yapılan çalışmalara göre yeryüzüne düşen toplam güneş ışınımı 1.278.1012 W olup bir yıl boyunca yer yüzüne düşen toplam güneş ışınımı (optik enerji) 1.119.1018 kWh'tir. Bu veriler doğrultusunda dünyanın bir yıllık enerji kullanımı 12,5 Milyar ton petrol karşılık gelir bu da 1.454.1014 kWh elektrik enerjisine eşdeğerdir. Bu sonuçlara göre yeryüzüne düşen güneş ışınımı ile dünyanın bir yıllık enerji kullanımını oranladığımızda, yeryüzüne düşen enerji miktarının, enerji kullanımından yaklaşık 8000 kat daha fazla olduğu ortaya çıkmaktadır. Belirli bir sürede tüenecek olan yenilenemez enerji kaynaklarının yerine, sürekli kendini yenileyen sınırsız olarak tanımlanabilen güneş enerjisinin kullanılması daha uygun görülmektedir (Yalçın 2019).

Güneş enerjisinden elektrik üretilmesi, üzerlerine güneş ışığı düştüğü zaman fotovoltaiik (FV) ilkeye dayalı olarak uçlarında elektrik gerilimi oluşan güneş hücreleri ile sağlanmaktadır. FV güneş panellerindeki bu hücreler yarı iletkenlerden oluşmuş yapılardır. Güneş hücreleri birbirlerine seri bağlanarak FV panelleri oluşturulmaktadır. Çok sayıda FV panelin kurulumu ile Güneş Enerjisi Santralleri (GES) oluşmaktadır. Günümüz teknolojisi kullanılarak Sahra Çölü'nde 800x800 km²'lik alandan kurulacak büyük bir GES'den elde edilecek elektrik enerjinin dünya elektrik ihtiyacını karşılayacağı hesaplanmıştır (Yalçın 2019).



Şekil 2.11. Sahra Çölü'nde 800x800 km² alan (Yalçın 2019).

Güneş enerji santralinde kurulacak olan FV güneş panellerinin verimi %10 alınarak ve tüm elektriksel kayıplar göz önünde bulundurularak hesaplamalar yapılmıştır. Fakat tek bir bölgede büyük güçte santraller kurulması yerine elektrik ihtiyaçlarının hesaplandığını farklı bölgelerde daha küçük güçte güneş enerji santralleri kurulması daha avantajlıdır. Çünkü hem enerjinin dağıtımı, hem işletme ve bakım durumu, hem de maliyet durumundan daha kolay ve hafifletici olmaktadır (Yalçın 2019).

2. KAYNAK ÖZETLERİ

Ülkemizde bulunan güneş enerji santrallerini ve bu santrallerin toplam üretim santralleri içerisindeki payına bakacak olursak 2014 yılı itibariyle santrallerin kurulumunun başladığı yıl içerisindeki kurulan güneş enerji santrallerinin gücünün 40.2 MW olduğu görülmekte olup bir sonraki sene içerisinde 248,8 MW değerine ulaşmışken 2022 yılındaki son durum ise 9425.4 MW güce ulaşmıştır. Enerji kaynaklarımızın 2014 yılındaki yerli kaynaklardaki kurulu gücümüz %52.9 kapsar iken 2022 yılında değerimiz %64.4 çıkmıştır. Değerlerimizdeki bu olumlu değişime güneş enerji santrallerinin de etkisi büyüktür. 2022 yılı içerisindeki kurulu gücümüzün % 9,08 güneş enerjisine aittir (Teiaş 2023).


Çizelge 2.1. Yıllara göre enerji kaynaklarının üretim kapasiteleri (Teiaş 2023)

YERLİ ENERJİ KAYNAKLARINA AİT KURULU GÜCÜN TÜRKİYE TOPLAM KURULU GÜCÜ İÇİNDEKİ PAYININ YILLAR İTİBARIYLA GELİŞİMİ ANNUAL DEVELOPMENT OF DOMESTIC RESOURCES BASED INSTALLED CAPACITY SHARE IN TURKEY TOTAL INSTALLED CAPACITY (2000-2022)												
Birim (Unit) : MW												
YILLAR	BARAJLI DAM	D.GÖL VE AKARS I.L.P.A.C AND RUN OF RIVER	HİDROLİ K TOPLAM TOTAL HYDRO	JEOTERMAL GEOTHERMAL	RÜZGAR WIND	GÜNEŞ SOLAR	YENİLENEBİLİR+ ATIK +ATIK ISI RENEW.+WASTES + WASTE HEAT	LİNYİT LIGNITE	TAŞKÖMÜRÜ + ASFALTİT HARD COAL +ASPHALTITE	YERLİ KAYNAK KURULU GÜCÜ DOMESTIC RESOURCES INSTALLED CAPACITY	TÜRKİYE TOPLAM KURULU TOTAL INSTALLED CAPACITY	YERLİ KAYNAK PAYI DOMESTIC RESOURCES SHARE %
2000	10.501,4	673,8	11.175,2	17,5	18,9		23,8	6.508,9	335,0	18.079,3	27.264,1	66,3
2001	10.959,4	713,5	11.672,9	17,5	18,9		23,6	6.510,7	335,0	18.578,6	28.332,4	65,6
2002	11.469,4	771,5	12.240,9	17,5	18,9		27,6	6.502,9	335,0	19.142,8	31.845,8	60,1
2003	11.752,4	826,3	12.578,7	15,0	18,9		27,6	6.438,9	335,0	19.414,1	35.587,0	54,6
2004	11.752,4	893,0	12.645,4	15,0	18,9		27,6	6.450,8	335,0	19.492,7	36.824,0	52,9
2005	11.967,4	938,6	12.906,1	15,0	20,1		35,3	7.130,8	335,0	20.442,3	38.843,5	52,6
2006	11.966,9	1.095,8	13.062,7	23,0	59,0		41,3	8.210,8	335,0	21.731,7	40.564,8	53,6
2007	12.262,0	1.132,9	13.394,9	23,0	147,5		42,7	8.211,4	335,0	22.154,5	40.835,7	54,3
2008	12.422,8	1.405,9	13.828,7	29,8	363,7		59,7	8.205,0	335,0	22.821,9	41.817,2	54,6
2009	12.681,7	1.871,7	14.553,3	77,2	791,6		86,5	8.199,3	470,0	24.177,9	44.761,2	54,0
2010	13.067,1	2.764,2	15.831,2	94,2	1.320,2		107,2	8.199,3	470,0	26.022,1	49.524,1	52,5
2011	13.529,3	3.607,7	17.137,1	114,2	1.728,7		125,7	8.199,3	470,0	27.775,0	52.911,1	52,5
2012	14.744,6	4.864,8	19.609,4	162,2	2.260,6		168,8	8.193,3	470,0	30.864,3	57.059,4	54,1
2013	16.142,5	6.146,6	22.289,0	310,8	2.759,7		235,0	8.223,2	470,0	34.287,7	64.007,5	53,6
2014	16.606,9	7.036,3	23.643,2	404,9	3.629,7	40,2	299,1	8.281,3	470,0	36.768,4	69.519,8	52,9
2015	19.077,2	6.790,6	25.867,8	623,9	4.503,2	248,8	370,1	8.663,4	755,0	41.032,2	73.146,7	56,1
2016	19.558,6	7.122,5	26.681,1	820,9	5.751,3	832,5	496,4	9.126,5	755,0	44.463,7	78.497,4	56,6
2017	19.776,0	7.497,1	27.273,1	1.063,7	6.516,2	3.420,7	641,9	9.129,1	782,5	48.827,2	85.200,0	57,3
2018	20.536,1	7.755,3	28.291,4	1.282,5	7.005,4	5.062,8	818,9	9.456,1	782,5	52.699,6	88.550,8	59,5
2019	20.642,5	7.860,5	28.503,0	1.514,7	7.591,2	5.995,2	1.170,5	9.966,0	782,5	55.523,1	91.267,0	60,8
2020	22.925,0	8.058,9	30.983,9	1.613,2	8.832,4	6.667,4	1.502,8	9.988,7	782,5	60.370,9	95.890,6	63,0
2021	23.280,4	8.212,2	31.492,6	1.676,2	10.607,0	7.815,6	1.642,7	9.988,7	812,5	64.035,3	99.819,6	64,2
2022	23.275,2	8.296,3	31.571,5	1.691,3	11.396,2	9.425,4	1.921,3	10.066,3	812,5	66.884,5	103.809,3	64,4
Not: Çok yakıtlı santrallerin kurulu gücü dahil değildir. Note: Installed capacity of multi-fired power plants is not included.												

Çizelge 2.2. Türkiye'nin kurulu gücü (Teiaş 2023)



Çizelge 2.3. Türkiye enerji kaynakları 2012-2022 kurulu gücü (Teiaş 2023)



2.11. Ardahan Gölle Bölgesinin Coğrafi Özellikleri

Gölle, Ardahan ilinin bir ilçesidir. İlçe, coğrafi koordinatları "40.79335 enlem" ve "42.609528 boylam" arasında yer almaktadır. İlçemiz, ortalama 2030 metre yükseklikteki düz bir arazi üzerine yer almaktadır. Köyler ise kısmen düz, yer yer yükseltisi olan bir arazide konumlanmıştır. Toplam yüzölçümü 1420 km² olan ilçenin arazisinin bir kısmı ormanlarla kaplıyken, diğer kısımları çayırlar ve meralarla örtülüdür. Tarım faaliyetleri arasında arpa, buğday ve patates yetiştirilmektedir. İlçenin iklimi, kışları uzun, çok sert ve soğuk; yazları ise ılık ve yağışlı bir karasal iklim özelliği göstermektedir.

Çevresine bakıldığında ilçe, kuzeyinde Ardahan İl Merkezi'ne, güneyi ve doğusu Kars İli'ne (Selim, Sarıkamış, Susuz ilçeleri), batısında Erzurum İli'ne (Şenkaya, Olur ilçeleri) ve kuzeybatısında Artvin İli'ne (Şavşat ilçesi) komşudur. İl merkezine uzaklık ise yaklaşık 42 km'dir.

2.12. İklim Verileri ve Analizi


Ardahan yöresinin yüksek olması ve yüzey şekillerinin değişkenlik göstermesi dolayısıyla, il genelinde karasal iklim hâkimdir. Bu nedenle, kışlar uzun, sert ve kar yağışlı geçer. Denizden yüksekliği 1800-2100 metre arasında değişen ve denize uzaklığı 211 km olan ilde, yaz mevsiminde en yüksek 35,0°C'ye kadar çıkabilen sıcaklıkların ortalaması 15°C civarında seyrederken, kışın -39,8°C'ye kadar düşen sıcaklık ortalaması ise -10°C civarındadır. Bu durum, yıllık sıcaklık farkının 75°C gibi büyük bir değerde olduğunu göstermektedir. Yıl, biri soğuk (kış), diğeri orta derecede sıcak (yaz) olmak üzere iki döneme ayrılmıştır. Geçiş mevsimleri oldukça kısa ve belirsizdir. Sert karasal iklimin hâkim olduğu Ardahan'da, yağışlar her mevsimde görülür ve genel olarak yaz aylarında fazladır. Bu iklim koşullarına bağlı olarak, karakteristik bitki örtüsü olarak uzun çayırlar hâkimdir. Yıllık toplam yağış miktarı ortalaması 555,6 mm'dir. Yağışların %12'si kış, %30'u ilkbahar, %41'i yaz ve %17'si sonbahar aylarında düşer. Kış aylarında ve bahar geçişinde sıcaklığın düşük olması nedeniyle, yağışlar genellikle kar şeklinde görünmektedir.

2. KAYNAK ÖZETLERİ

Göle Ovası'nda kışlar ağır geçer. Her tarafı yüksek dağlarla çevrili olan bu çanak biçimindeki ovada, kışın hava akımı az olur. Bu durumda soğuyan ve ağırlaşan hava aşağı doğru hareket eder ve sıcaklık kaybına uğrayarak dondurucu bir hal alır. Posof ilçesi ise etrafı dağlarla çevrili ve ortalama 1.400 m yükseklikte bulunmaktadır. Burada Doğu Karadeniz ikliminin sert şekli hüküm sürer ve mikroklima tipi iklim hâkimdir. Kışlar yağışlı, yazlar ise sıcak geçmektedir. İl genelinde sıcaklık, yağışlardan ve havanın sık sık bulutlu kalmasından etkilenir. Yaz mevsimi adeta bir ilkbahar serinliğindedir. Bu nedenle, geniş ormanların varlığı kendiliğinden oluşur ve açık kalan yerler ile vadiler devamlı bir yeşillik içerisinde. (Ardahan Afad 2023)


2.13. Güneşlenme Süresi ve Radyasyon Değerleri

Ardahan'ın güneş radyasyon haritası detaylı olarak Şekil ...'de gösterilmektedir. Ayrıca ilin günlük global radyasyon değerleri ve güneşlenme süreleri ay bazında, ilgili Şekil 2.12'de sunulmuştur.




Şekil 2.12. Ardahan ili güneş radyasyonu (GEPA)

2. KAYNAK ÖZETLERİ



Şekil 2.13. Göle ilçesi aylık güneşlenme tablosu (GEPA)

Mayıs ayında güneşlenme süresi 8 saatin altında seyrederken, Haziran, Temmuz ve Ağustos aylarında 9 saatin üzerindedir; yılın maksimum güneşlenme süresi Temmuz ayında 9 saatin üzerindedir. Eylül ayında ise güneşlenme süresi 7 saatin üzerindedir. Minimum güneşlenme süresi ise Aralık ayında görülür.



Şekil 2.14. Göle GES kullanılan paneller ve üretim değerleri (GEPA)

2.14. Ardahan Göle Bölgesi ve Güneş Enerji Potansiyeli

Ardahan ilinin elektrik santrali kurulu gücü 221 MW'dır. Toplamda, 5 adet Hidroelektrik Enerji Santrali (HES) ve 5 adet Güneş Enerji Santrali (GES) bulunmaktadır. Bu santrallerle yılda yaklaşık 440 GWh elektrik üretilmektedir. Elektrik dağıtım hizmeti ise ARAS Elektrik Dağıtım tarafından sağlanmaktadır.

Çizelge 2.4. Ardahan GES kapasiteleri (AFAD)

Tablo 1.7 Ardahan ilindeki güneş santralleri.

Sıra	Santral	Tesis	Firma	Kurulu Güç (MW)
1	Fatih Demirci GES	Güneş	Fatih Demirci GES	0,630
2	Selma Demirci GES	Güneş	Selma Demirci GES	0,630
3	Erkan Kalem GES	Güneş	Erkan Kalem GES	0,800
4	Göle Merkez GES Kabin	Güneş	Göle Belediyesi	1,250
5	Köprülü GES Kabin	Güneş	Köprülü Belediyesi	0,315

2.15. Santralin Teknik Özellikleri

Göle Belediyesi, Belediye Başkanı İlhan Gültekin'in liderliğinde, artık kendi elektriğini üretecek bir güneş enerji santrali kurmuştur. Bu santral, 999 kW, 2556 panel, 91 masa, 15 sıra ve 10 inventörden oluşmaktadır. Ayrıca, santral 850 metrelik bir hattı kullanmaktadır. Santral, Göle'nin elektrik ihtiyacının yaklaşık dörtte birini karşılayacak kapasitededir. Bu, belediyenin 25 yıl boyunca ilçeye hizmet edecek bir enerji kaynağı sağlaması anlamına gelmektedir. Santral, 2020 yılı bitmeden üretime başlamıştır. Üretilen elektriğin tamamı, 13.3 Senden elektrik dağıtım şirketi ile yapılan bir anlaşma ile satışa sunulmuştur. Bu, belediye bütçesine ciddi bir katkı sağlamaktadır. Santral, yaklaşık yirmi dönüm arazi üzerine kurulmuştur ve temiz bir enerji kaynağı olan güneş enerjisi ile elektrik üretmektedir. Bu, tüm halk için hayırlı bir gelişme olarak kabul edilmektedir. Göle Belediyesi, tüketen değil, üreten bir belediye olma yolunda ilerlemektedir. Bu, belediyenin sürdürülebilir bir gelecek için adımlar attığını göstermektedir.

3. MATERYAL VE YÖNTEM

Kullanacağımız materyaller arasında en iyi sonucun metrolojik verilere bağlı olarak yapay zekâ alt alanları kullanılması olarak görünmektedir.

3.1. Yapay Zeka

Günümüzde, bilgisayar sistemleri yapay zeka çalışmalarını kullanarak, Matematiksel ilişkilerin belirlenmesinin güç olduğu problemlerde sezgisel tekniklerle çözümleme yapabilir ve olaylar hakkında ilişki kurarak karar verebilir. Problemlerin çözümü için tasarlanmış formül ve algoritmalar, klasik bilgisayar sistemleriyle gerçekleştirilebilir. Ancak, Çözüm sağlanamadığı hallerde yapay zeka yöntemleri kullanarak Problemi daha hızlı çözmeyi sağlamaktır (Öztemel 2012).

Yapay zeka, canlı bir varlığın yardımı olmadan insanların zihinsel eylem ve davranışlarını ortaya koyabilen makineleri yaratma ve geliştirme teknolojisidir. Günümüzde, yapay zekâ uygulamaları hayatımızın her yerinde bulunmaktadır; bankada, arabada, hastanede, evde, internette, mobil cihazlarda ve daha birçok alanda günlük yaşamımızın bir parçası haline gelmiştir. Günlük hayatta herkesin yaptığı Google araması, bu teknolojinin en basit örneğidir. Google arama motorları, yapay zekâ teknolojilerine dayanarak çalışır. Bunun yanı sıra, sağlık, finans ve ulaşım sistemleri de yapay zekâ teknolojilerinden faydalanmaktadır. Günümüzde 60'tan fazla yapay zeka tekniklerinden söylenmektedir. Bu tekniklerden önde gelenleri şunlardır (Paksın 2020).

- Yapay Sinir Ağları
- Makine Öğrenmesi
- Bulanık Mantık
- Genetik Algoritmalar

Yapay zeka (YZ) alanında Yapay Sinir Ağları (Artificial Neural Networks - ANN) ve ANFIS (Adaptive Neuro-Fuzzy Inference System), özellikle veri modelleme, sınıflandırma, regresyon ve tahminleme gibi görevlerde yaygın olarak kullanılan güçlü

algoritmalarıdır. Her iki yöntem de öğrenme süreçlerinde matematiksel algoritmalar kullanarak girdilerle çıktılar arasında ilişkiler kurar.

Bir yapay sinir ağındaki hesaplamalar, her nöron için şu şekilde yapılır:

$$z_j = \sum_{i=1}^n (w_{ij}x_i + b_j)$$

Aktivasyon fonksiyonu $f(z)$ ile çıkış hesaplanır:

$$y_j = f(z_j)$$

Burada:

- x_i : Girdi verileri,
- w_{ij} : Ağırlıklar,
- b_j : Bias,
- y_j : Çıktı değeri.


Backpropagation (geri yayılma), ağı tahmin hatasını minimize etmek için kullanılır. Bu, ağırlıkların güncellenmesini sağlar.

3.1.1. Yapay sinir ağları (YSA)

Temel olarak insan beyni yapısından esinlenerek geliştirilmiş bir algoritma olan yapay sinir ağları (YSA) 1943 yılında, nöroloji uzmanı Warren McCulloch ve matematikçi Walter Pitts, insan beynindeki sinir hücrelerinin, yani nöronların iletim prensibini makinelerle adapte edilerek bilgisayarlarda öğrenebilir mi düşüncesi üzerine çalışmalarını geliştirmişlerdir. (Özdemir 2022)

Önce insan beyninin çalışma prensibini anlayarak, yapay sinir ağlarını anlamakta fayda var. İnsan beyni, bilgiyi elektrik sinyalleri şeklinde işleyen milyonlarca nöronlardan

meydana gelir. Bir sinir hücresi, dentrit, hücrenin gövde kısmı ve akson gibi 3 temel yapıdan oluşunu sağlar. Bu nöronlar arasındaki iletişimi sağlayan sinaps adı verilen boşluklar, kimyasal ve elektriksel iletim için gerekli olan nörotransmitter maddeleri içerir. Bu maddeler arasında sodyum, potasyum, kalsiyum ve klor gibi iyonlar bulunur. Dentritler aracılığıyla alınan sinyali (uyarıyı) alan sinir hücresi, hücre gövdesi ve aksonlar vasıtasıyla bu sinyali sinaps boşluğuna iletir. Sinaps boşluğundaki maddeler aracılığıyla gelen sinyal, elektriksel ve kimyasal iletim yoluyla bir diğer sinir hücresine aktarılır. Beynimizde olan çalışma Şekil 'de bir tanesi gösterilmiştir, bu işlem nöronlar aracılığı ile olmaktadır. Şekil 'de insan beyninde milyonlarca bulunan, hem kimyasal hem elektriksel iletimi sağlayan bir sinir hücresi görülmektedir. (Özdemir 2022)



Şekil 3.1. Sinir ağı yapısı

Çok katmanlı yapay sinir ağı (ÇKYSA), özellik kümesiyle bu özelliklere karşılık gelen hedef (çıkış) değerleri arasında doğrusal olmayan bir eşlemeyi temsil eden bir modeldir. Denetimli öğrenme yöntemini kullanan ÇKYSA, girişleri ve bunlara karşılık gelen hedef çıkışları alır. Şekil 'de gösterildiği gibi, ÇKYSA basit birbirine bağlı nöronlar veya düğümler sistemiyle oluşur. Düğümler, girişlerin toplamının bir fonksiyonu olan ağırlıklar ve çıkış sinyalleri ile bağlanır ve basit bir doğrusal olmayan aktivasyon fonksiyonu tarafından değiştirilir. Giriş katmanında, veri kümesindeki özellik sayısı kadar nöron bulunur ve giriş katmanı uygulanan veri kümesini değişikliğe uğratmadan gizli katmana iletir. ÇKYSA, Bir ya da birden fazla gizli katman ve en son bir çıkış katmanı içerir ve eğitim yoluyla öğrenme yeteneğine sahiptir. Eğitim, bir dizi girdi ve onlara karşılık gelen çıktı vektörlerinden oluşan eğitim verisi gerektirir. ÇKYSA, eğitim

sırasında verilen verileri ağı tekrar tekrar sunar ve ağıdaki ağırlıklar, istenen çıktı elde edilene kadar girişlere karşılık gelen eşlemeyi oluşturacak şekilde değiştirilir. Eğitim sırasında, belirli bir giriş vektörü için ağı çıkışında hesaplanan çıktı, istenen çıktıya eşit olmayabilir; bu durumda hesaplanan ve gerçek çıktı arasındaki farktan hata hesaplanır. ÇKYSA'yı eğitmek için çeşitli algoritmalar kullanılabilir ve genellikle hatayı minimum yapmak için geriye yayılım eğitim algoritması olarak bilinen gradyan iniş algoritması tercih edilir. Eğitimin amacı, en küçük hatayla sonuçlanan ağırlıkların kombinasyonunu bulmaktır. Ağı, hatayı azaltmak için ağıdaki ağırlıkları değiştirerek çıkıştaki hatayı geriye ileterek işlev görür. Bu şekilde, hata ağıda geriye doğru yayılarak toplam hatayı en aza indirir. Bu öğrenme algoritması, hatayı minimize etmeyi hedefler. Bu hesaplamada 1 gizli katmanın çıkışı 2. gizli katmanın yollardaki çarpanlar ile çarpılarak girişini, 2 gizli katmanın çıkışı 3. çıkış katmanının yollardaki çarpanlar ile çarpılarak girişini oluşturur (Somuncu 2023).

Matematiksel Algoritma ve İşleyiş

Yapay sinir ağlarının temel matematiksel yapısı, katmanlar arasındaki bağlantıları ve aktivasyon fonksiyonlarını içerir. Aşağıda temel bir yapay sinir ağının matematiksel modelini ve algoritmasını bulabilirsiniz.

- Giriş Katmanı (Input Layer)

Giriş katmanına gelen her bir veri $x_1, x_2, \dots, x_n$ ağırlıklı bir şekilde bir sonraki katmana iletilir.

- Ağırlık ve Bias

Her bağlantıya, ağırlık (weight) ve bias (bias) atanır. Ağırlık, her bağlantının önemini belirler. Bias, modelin doğruluğunu artıran ek bir parametredir.

- Hesaplama (Ön Yönlü Yayılma - Forward Propagation)

Bir katmandaki çıktı, bir önceki katmandan gelen verilerin ağırlıklı toplamı olarak hesaplanır. Genel formül:

$$z_j = \sum_{i=1}^n (w_{ij}x_i + b_j)$$

- Aktivasyon Fonksiyonu (Activation Function)

Her nöron, gelen toplam girişi bir aktivasyon fonksiyonu ile işler. Aktivasyon fonksiyonları, ağırlık doğrusal olmayan hesaplamalar yapmasına olanak tanır. Yaygın olarak kullanılan aktivasyon fonksiyonları:

Sigmoid:

$$f(z) = \frac{1}{1 + e^{-z}}$$

ReLU:

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

Tanh:

$$f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

- Çıkış Katmanı (Output Layer)

Sonuç, çıkış katmanında hesaplanır ve modelin tahmini değeri elde edilir.

$$\hat{y} = f(z_L)$$

- Hata Hesaplama (Error Calculation)

Elde edilen tahmin ile gerçek değer arasındaki hata hesaplanır. Genellikle hata, mean squared error (MSE) kullanılarak hesaplanır:

$$E = \frac{1}{2} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

- Geriye Yayılma (Backpropagation)


Hata, geriye doğru yayılır ve ağırlıklar güncellenir. Bu işlem gradyan inişi kullanılarak yapılır. Ağırlıklar, hata fonksiyonunun gradyanına göre güncellenir:

$$w_{ij} = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}}$$

Burada:

- η öğrenme oranını,
- $\frac{\partial E}{\partial w_{ij}}$ ağırlıkların gradyanını belirtir.

Özetle yapay sinir ağları, giriş verilerini işleyerek doğru tahminler yapabilen ve öğrenme süreciyle ağırlıklarını güncelleyebilen matematiksel modellerdir. Bu ağlar, hem doğrusal hem de doğrusal olmayan ilişkileri öğrenebilir ve birçok alanda geniş uygulama alanına sahiptir. Algoritmalar, öncelikle ileriye doğru propagasyon ve geri yayılma adımlarından oluşur.



Şekil 3.2. İleri beslemeli ÇKYSA yapısı

Gizli katman, girdi katmanından aldığı veriyi ağırlıklarıyla çarparak bir uyum fonksiyonuyla işleyerek sonraki katmana iletir. Toplama fonksiyonu, yapay sinir hücresine gelen net girdi değerini hesaplar ve bu amaçla çeşitli fonksiyonlar kullanılır, en yaygın olanı ağırlıklı toplamdır. Bu durumda, yapay sinir hücresine gelen girdi değerleri kendi ağırlıkları ile çarpılarak toplanır ve böylece ağa gelen net girdi değeri hesaplanmış olur. Yapay sinir hücresinin önemli bir bileşeni de aktivasyon fonksiyonudur, bu fonksiyon toplama fonksiyonu üzerinden gelen verileri çıktıya dönüştürür. Aktivasyon fonksiyonu, çıktıyı hesaplamak için farklı metotlar içerebilir ve problemin çeşidine ve kullanılan ağ yapısına bağlı olarak çeşitli fonksiyonlar tercih edilebilir. Genellikle aktivasyon fonksiyonları olarak basamak, doğrusal, sigmoid ve hiperbolik tanjant fonksiyonları kullanılır. Yapay sinir ağının en üst katmanı çıkış katmanı olarak bilinir ve gizli katmandan gelen bilgiyi ağın kullandığı fonksiyonla işleyerek çıktı üretir. Çıkış katmanındaki nöron sayısı, ağa gönderilen verilerin çıkış sayısına eşittir (Somuncu 2023).

Yapay sinir ağlarında kullanılan farklı eğitim algoritmalarının (trainlm, trainbr, trainscg) matematiksel algoritmaları ve açıklamaları şu şekilde sıralanabilir:

3.1.1.1. Trainlm (levenberg-marquardt algoritması)

Matematiksel Formül: Levenberg-Marquardt algoritması, genellikle Newton-Raphson yöntemi ve gradyan inişi yönteminin birleşimi olarak kabul edilir. Aşağıdaki formül ile ifade edilebilir:

$$w^{(k+1)} = w^{(k)} - [J^T J + \lambda I]^{-1} J^T e$$

Burada:

- $w^{(k)}$: Ağırlıklar
- J : Jacobian matrisi
- λ : Damping parametresi (başlangıçta küçük, sonra artırılır)
- e : Hata vektörü
- I : Kimlik matrisi

Levenberg-Marquardt (LM) algoritması, doğrusal olmayan en küçük kareler problemlerini çözmek için kullanılır ve hız açısından çok verimlidir. Bu algoritma, bir tür iteratif optimizasyon yöntemidir ve genellikle geriye yayılım (backpropagation) algoritması ile birlikte kullanılır. Bu algoritma, modelin tahmin hatalarını minimize etmek için ağırlıkları günceller. Genellikle eğitim süreçlerinde daha hızlı yakınsama sağlar.

3.1.1.2. Trainbr (bayesian regularization algoritması)

Matematiksel Formül: Bayesian Regularization, ağırlıkların ve bias'ların birlikte optimize edilmesinde bayesyen çıkarım yöntemlerini kullanır. Bu, ağırlıkların büyük olmasını engelleyerek modelin aşırı öğrenmesini (overfitting) engellemeye yardımcı olur. Matematiksel olarak şöyle ifade edilebilir:

$$E_{total} = E_{data} + \lambda E_{regularization}$$

Burada:

- E_{total} : Toplam hata fonksiyonu
- E_{data} : Jacobian matrisi
- λ : Regularizasyon parametresi
- $E_{regularization}$: Hata vektörü

Trainbr algoritması, ağırlıklar üzerinde bayesyen regularizasyon ekler. Bu, modelin genelleme yeteneğini artırmak için ağırlıkları çok büyük yapmamayı amaçlar. Bayesyen regularizasyon, modelin doğruluğunu artırırken aşırı öğrenmeyi engellemeye yardımcı olur ve genellikle daha iyi sonuçlar elde edilir. Bu algoritma, tahminlerin doğruluğunu iyileştirmek için veri ve model arasındaki dengenin optimize edilmesine odaklanır.

3.1.1.3. Trainscg (scaled conjugate gradient algoritması)

Matematiksel Formül: Scaled Conjugate Gradient (SCG) algoritması, conjugate gradient yönteminin bir versiyonudur ve aşağıdaki formüllerle ifade edilir:

$$w^{(k+1)} = w^{(k)} - a^{(k)}d^{(k)}$$

Burada:

- $w^{(k)}$: Ağırlıklar
- $a^{(k)}$: Öğrenme oranı
- $d^{(k)}$: Konjugat doğrultu (gradient yönünden türetilmiş)

Scaled Conjugate Gradient algoritması, öğrenme hızını optimize eden bir yöntem olarak kullanılır. Bu algoritma, her iterasyonda ağırlıkların en uygun değerini bulmak için gradient (gradyan) bilgisini kullanır. SCG, özellikle büyük veri setlerinde daha hızlı çalışır ve öğrenme sırasında daha verimli sonuçlar üretir. Bu algoritma, çok büyük parametre uzaylarında da hızlı ve etkili eğitim sağlar.

- trainlm: Levenberg-Marquardt algoritması, hızlı ve verimli yakınsama sağlamak için kullanılır.
- trainbr: Bayesian regularization, aşırı öğrenmeyi engelleyerek genelleme yeteneğini artırır.
- trainscg: Scaled Conjugate Gradient algoritması, büyük veri setleri için hızlı ve verimli öğrenme sağlar.

3.1.2. Anfis

ANFIS (Adaptive Neuro-Fuzzy Inference System), hem yapay sinir ağları (ANN) hem de bulanık mantık (Fuzzy Logic) özelliklerini birleştirerek karmaşık sistemlerin modellenmesinde ve tahmin edilmesinde kullanılan güçlü bir yapıdır. ANFIS'in üyelik fonksiyonu sayısının değiştirilmesi, ağırlık karmaşıklığını ve doğruluğunu etkileyebilir.

ANFIS'in matematiksel algoritmalarını ve açıklamalarını, üyelik fonksiyonlarının sayısına bağlı olarak aşağıda detaylandırılmıştır. ANFIS'in temel yapısını açıklayarak, 222, 333, ve 444 üyelik fonksiyonu sayıları ile ilgili örnekleri sunacağım.

ANFIS Temel Yapısı

ANFIS, tipik olarak beş katmandan oluşur:

- **Input Layer (Girdi Katmanı):** Girdi değişkenlerini alır.
- **Fuzzification Layer (Bulanıklaştırma Katmanı):** Girdi değişkenlerini üyelik fonksiyonları aracılığıyla bulanık değerlere dönüştürür.
- **Rule Layer (Kural Katmanı):** Bulanık değerler üzerinden bulanık mantık kuralları uygulanır.
- **Normalization Layer (Normalizasyon Katmanı):** Kuralların etkinliğini normalize eder.
- **Defuzzification Layer (Bulanıklaştırma Katmanı):** Çıktıları defuzzifiye eder, yani bulanık çıkışları belirli bir değere dönüştürür.

Girdi ve Çıktı İlişkisi:

Girdi $x_1, x_2, \dots, x_n$ ve çıktı y arasındaki ilişkiyi ifade eden model:

$$y = \sum_{i=1}^n w_i \cdot f_i(x_1, x_2, \dots, x_n)$$

Burada:

w_i : Her bir kuralın aktivasyon değeri (genellikle, üyelik fonksiyonlarının çarpımıdır)

$f_i(x_1, x_2, \dots, x_n)$: Her bir kuralın çıktısı

ANFIS, parametrelerini optimize etmek için girdiler ve çıktılar arasındaki ilişkiyi öğrenmeye çalışır.

ANFIS Üyelik Fonksiyonu Sayısına Göre Modelin Değişimi

ANFIS'in üyelik fonksiyonu sayısı arttıkça modelin doğruluğu ve karmaşıklığı değişir. Aşağıda, 222, 333 ve 444 üyelik fonksiyonları ile ilgili algoritmalar ve açıklamalar yer almaktadır:

ANFIS Üyelik Fonksiyon Sayısı 222

Bu, her bir girdinin iki adet üyelik fonksiyonuna sahip olduğu bir durumdur. Bu, daha basit bir model oluşturur ve daha az parametre içerir.

Matematiksel Formül:

Eğer x_1 ve x_2 girdileri için iki üyelik fonksiyonu (örneğin, Gaussian ya da Triangular üyelik fonksiyonları) varsa:

$$\mu_{A1}(x_1) = \exp\left(-\frac{(x_1 - c_1)^2}{2\sigma_1^2}\right)$$

$$\mu_{A2}(x_2) = \exp\left(-\frac{(x_2 - c_2)^2}{2\sigma_2^2}\right)$$

Burada:

c_1, c_2 : Üyelik fonksiyonunun merkez değerleri

σ_1, σ_2 : Üyelik fonksiyonunun yayılma parametreleri

Çıktı ise, kural tabanlı sistemle birleştirilerek şu şekilde hesaplanır:

$$y = \sum_{i=1}^n w_i \cdot f_i(x_1, x_2)$$

ANFIS Üyelik Fonksiyon Sayısı 333

Bu durumda her bir girdi için üç adet üyelik fonksiyonu kullanılır. Bu daha karmaşık bir model ortaya çıkar ve daha fazla parametre optimize edilir.

Matematiksel Formül:

Her girdi için üç adet üyelik fonksiyonu (örneğin, Gaussian):

$$\mu_{A1}(x_1) = \exp\left(-\frac{(x_1 - c_1)^2}{2\sigma_1^2}\right)$$

$$\mu_{A2}(x_1) = \exp\left(-\frac{(x_1 - c_2)^2}{2\sigma_2^2}\right)$$

$$\mu_{A3}(x_1) = \exp\left(-\frac{(x_1 - c_3)^2}{2\sigma_3^2}\right)$$

Ve her biri için benzer şekilde x_2 ve diğer girdiler için de aynı şekilde üyelik fonksiyonları tanımlanır.

Çıktı şu şekilde hesaplanır:

$$y = \sum_{i=1}^n w_i \cdot f_i(x_1, x_2, x_3)$$

ANFIS Üyelik Fonksiyon Sayısı 444

Bu durumda her girdi için dört adet üyelik fonksiyonu vardır. Bu daha karmaşık ve esnek bir model oluşturur, ancak hesaplama maliyeti ve parametre sayısı artar.

Matematiksel Formül:

Her bir girdi için dört üyelik fonksiyonu (örneğin, Gaussian) kullanılır:

$$\mu_{A1}(x_1) = \exp\left(-\frac{(x_1 - c_1)^2}{2\sigma_1^2}\right)$$

$$\mu_{A2}(x_1) = \exp\left(-\frac{(x_1 - c_2)^2}{2\sigma_2^2}\right)$$

$$\mu_{A3}(x_1) = \exp\left(-\frac{(x_1 - c_3)^2}{2\sigma_3^2}\right)$$

$$\mu_{A4}(x_1) = \exp\left(-\frac{(x_1 - c_4)^2}{2\sigma_4^2}\right)$$

Çıktı şu şekilde hesaplanır:

$$y = \sum_{i=1}^n w_i \cdot f_i(x_1, x_2, x_3, x_4)$$

- **Üyelik Fonksiyonları:** Her bir girdi değişkeninin, belirli bir üyelik fonksiyonu ile bulanık hale getirilmesi işlemi fuzzification olarak adlandırılır. ANFIS'te genellikle Gaussian, Triangular veya Trapezoidal üyelik fonksiyonları kullanılır.
- **Kural Tabanlı Sistem:** ANFIS, bulanık mantık kuralları kullanarak girdiler arasındaki ilişkiyi modeller. Her bir kuralın çıktısı, ilgili üyelik fonksiyonlarının çarpımı ile hesaplanır.

- **Ağırlıklar ve Öğrenme:** ANFIS, hem sinir ağı özelliklerini hem de bulanık mantık sistemini birleştirir. Ağırlıklar, modelin eğitim sürecinde, girdiler ile çıktılar arasındaki ilişkiyi öğrenmek için optimize edilir.



4. BULGULAR

Bu bölümde, güneş enerji santrali çıkış enerjisi tahmini için elde edilen bulgular sunulmaktadır. Tez çalışmamda GÖLE BELEDİYESİ güneş enerji santrali 999 kW üretim tesisinin 2022 ve 2023 verileri incelenmiş olup bu tarihler arasında üretilen günlük veriler ile Ardahan Meteoroloji istasyon Müdürlüğünden alınan günlük veriler kullanılmıştır. Bu değişkenlere bakacak olursak; gün, ay, Günlük Güneşlenme Süresi, Günlük Maksimum Sıcaklık, Günlük Minimum Sıcaklık, Günlük Ortalama Aktüel Basınç, Günlük Ortalama Bulutluluk, Günlük Ortalama Kar Yüksekliği, Günlük Ortalama Nispi Nem, Günlük Ortalama Sıcaklık, Günlük Toplam Yağış gibi değerler alınarak günlük üretim verileri kayıt altına alınmıştır.

Analizler sonucunda 10 eviriciden elde edilen üretim verileri ışığında 2024 yılının üretim sonuçlarını tahmin edilebilmesi için, METEROLOJİDEN alınan günlük verileri öğrenmede kullanılmıştır. Bu değişkenler ; gün, ay, Günlük Güneşlenme Süresi, Günlük Maksimum Sıcaklık, Günlük Minimum Sıcaklık, Günlük Ortalama Aktüel Basınç, Günlük Ortalama Bulutluluk, Günlük Ortalama Kar Yüksekliği, Günlük Ortalama Nispi Nem, Günlük Ortalama Sıcaklık, Günlük Toplam Yağış gibi değerler 2024 verileri sonucunda üretilen güç değeri tahmini yapılmıştır.

Güneş enerjisi çıkış tahmini için ÇKYSA (Çok Katmanlı Yapay Sinir Ağı) ve ANFIS (Uyarlanabilir Nöro-Fuzzy İnerans Sistemi) yöntemleri uygulanmıştır. Başarım değerlendirmesi için, ortalama kare hata (MSE) ve kök ortalama kare hata (RMSE) gibi performans metrikleri hesaplanmıştır. Tüm analizler MATLAB programı kullanılarak gerçekleştirilmiştir.

4.1. Çok Katmanlı Yapay Sinir Ağı Uygulaması

Bu bölümde, çok katmanlı ileri beslemeli yapay sinir ağı algoritması kullanılmıştır. Farklı öğrenme yöntemleri seçilerek ve gizli katmandaki nöron sayısı değiştirilerek çeşitli modeller test edilmiş ve sonuçlar karşılaştırılmıştır. ÇKYSA modeline ait girdi değişkenleri şu şekildedir;

Çizelge 4.1. Girdi listesi

Tarih (gün)
Günlük Güneşlenme Süresi (saat)
Günlük Maksimum Sıcaklık (°C)
Günlük Minimum Sıcaklık (C)
Günlük Ortalama Aktüel Basınç (hPa)
Günlük Ortalama Bulutluluk (8 Okta)
Günlük Ortalama Kar Yüksekliği (cm)
Günlük Ortalama Nispi Nem (%)
Günlük Ortalama Sıcaklık (°C)
Günlük Toplam Yağış (mm=kg÷m ²) OMGI

Kullanılacak veriler ilk önce ay bazlı olarak değerlendirilmiş fakat ay bazlı değerlendirildiğinde veriler yeteri kadar olmadığı için ay içerisindeki bütün verilerin ortalaması alındığında çok üst düzey sonuçların elde edilmediğin görülmektedir. Bu nedenle veriler günlük olarak kullanılmaya karar verilmiştir. Alınan günlük verilerin hepsini değerlendirip bir öğrenme yapabilmesi için yapay sinir ağına verilecek değerlerin çeşitli olması sinir ağının algoritmasını karıştırmaktadır. Basınç değeri 800 görünmekte iken sıcaklık 3 olarak elde edilmektedir.


Bunun için kullanılan veriler en üst ve en alt kriter baz alınarak [0 1] aralığında normalize edilmiştir. Kullanılan veri setinde 2022-2023 yılı için her güne ait ortalama değerler kullanılmıştır. 2024 yılındaki 274 günlük Veri ise test amacı ile kullanılmıştır. Ayrıca doğrulama için eğitim setinden rasgele seçilen %10'luk veri kullanılmıştır.

Sistemin eğitilmesi amacıyla en iyi değerleri sağlayan modelleri kontrol edilmiştir. Değerlendirme daha kapsalı yapabilmesi için fonksiyonlar incelenmiştir. Trainlm (Levenberg-Marquardt), küçük ve orta ölçekli ağlar için en hızlı sonuçları verir, ancak bellek ve hesaplama gereksinimleri yüksek olabilir. Trainscg (Scaled Conjugate Gradient), büyük ağlar ve veri setleri için bellek dostudur ve daha büyük veri setlerinde

kullanılır. Trainbr (Bayesian Regularization), özellikle küçük veri setlerinde overfitting (aşırı öğrenme) problemini önlemek için kullanılır ve genelleme yeteneği sağlaması özelleri göz önüne getirildiğinde değerlendirme aşamasında veri kümemize en uygun ve en kapsamlı bu 3 fonksiyon görülmüştür. Yapılan kontroller neticesinde aralarındaki en iyi sonucu veren 3 farklı eğitim fonksiyonu kullanılmıştır. Kullanılan bu fonksiyonlar neticesinde eğitimi gerçekleştirilen sistemin yaptığı tahmin sonuçları da ayrı ayrı karşılaştırılarak en iyi başarımların elde edilmesi amaçlanmıştır. Kullanılan bu değerlendirme ölçütleri; trainlm, trainscg, trainbr olarak kullanılmıştır. Bu değerlendirme ölçütlerinden hatası en düşük olan en başarılı değerlendirme ölçütü olarak görülmektedir.


4.1.1. Trainlm değerlendirme ölçütü

Trainlm (Levenberg-Marquardt algoritması), doğrusal olmayan en küçük kareler problemlerini çözmek için kullanılır ve hız açısından çok verimlidir. Bu algoritma, bir tür iteratif optimizasyon yöntemidir ve genellikle geriye yayılım (backpropagation) algoritması ile birlikte kullanılır. Bu algoritma, modelin tahmin hatalarını minimize etmek için ağırlıkları günceller. Genellikle eğitim süreçlerinde daha hızlı yakınsama sağlar. Yapay sinir ağlarını eğitmek için kullanılan bir geri yayılım (backpropagation) algoritmasıdır. Bu algoritma, özellikle küçük ve orta ölçekli veri setleriyle çalışan yapay sinir ağları için hızlı ve verimli bir eğitim yöntemi olarak tercih edilir. Burada yapay sinir ağımızın eğitim, doğrulama, test ve tüm değerleri kontrol edilecektir.




Şekil 4.1. ÇKYSA trainlm 10 nöronlu tahmin sonuçları

Şekil 4.1 de tahmin edilen çıkış enerjisi değerleri ile sistemin gerçek çıkış değerlerinin ÇKYSA modeline göre eğitim, doğrulama, test ve tüm değerler bakımından aralarındaki ilişkiyi göstermektedir. Buna göre eğitim verileri için başarı oranı % 88,56, doğrulama verileri için başarı oranı %91,34, test verileri için başarı oranı ise %88,39 olarak bulunmuştur. Ayrıca ağ yapısındaki tüm veriler için başarı oranı % 88,93 olarak bulunmuş olup bu değerler eğitilen ağın yeterince başarılı olduğunu ortaya koymaktadır.



Şekil 4.2. Trainlm hata dağılımı

Şekil 4.2, hata değerlerinin histogramını sunmaktadır. Yatay ekseninde hata değerleri (gerçek ile tahmin edilen değerler arasındaki fark) yer alırken, dikey ekseninde örnek sayıları gösterilmektedir. Şekilde hataların çoğunluğunun -0,03743 ile 0,04579 arasında dağıldığı, en yüksek hata değeri olan 0,004182'in ise belirgin bir yoğunluk gösterdiği gözlemlenmektedir.



Şekil 4.3. Trainlm eğitim, test ve doğrulama verilerinin başarımlarındaki değişim

Şekil 4.3, her bir iterasyondaki eğitim, test ve doğrulama verilerine dayalı eğitim süresindeki başarımların değişimini göstermektedir. Modelin performans grafik incelendiğinde, en düşük hata değeri 8. iterasyonda elde edilmiştir.

Ayrıca, YSA modellerinin eğitim aşamasında aşırı öğrenme (overfitting) durumunun olup olmadığının kontrol edilmesi önemlidir. Bu kontrol, eğitim sürecinde eğitim ve doğrulama setlerindeki hata değerlerinin izlenmesiyle gerçekleştirilebilir. Eğitim iterasyonları sırasında test ve doğrulama hata eğrilerinin zıt yönlerde hareket etmesi istenmeyen bir durumdur ve bu, YSA eğitiminde istenilen başarıya ulaşılamadığına işaret eder. Şekil 4.3'te, en iyi sonuç veren YSA eğitiminin hata kayıt grafi incelendiğinde, 8. iterasyonda eğitimin tamamlandığı anlaşılmaktadır. Grafikte yeşil daire ile gösterilen iterasyonda en düşük doğrulama hatası kaydedilmiştir. Test ve doğrulama hata vektörlerinin benzer bir eğilim gösterdiği gözlemlenmektedir. Bu durumda, oluşturulan YSA modelinin eğitim aşamasında aşırı öğrenme durumunun ortaya çıkmadığı sonucu çıkarılmaktadır.

Trainlm algoritmaları nöron sayılarını belirlerken nöron sayılarının artırılması kullandığımız veriler doğrultusunda daha karmaşık yapılarda hangi nöron sayısı ile ne kadar doğru çalıştığını göstermektedir. Burada nöron sayılarını sıralı olarak artırarak öğrenmenin derecelerini ölçmek görmek isterken nöron sayılarını artırıp kontrol sağladık ilk başladığımız nöron sayısının 10 katını verip çok karmaşık yapılarda nasıl tahminde bulunacağını görmek istemiştir. 5, 10, 15, 20, 50 nöron sayıları kullanılarak elde edilen

4. BULGULAR

Ortalama Kare Hata (MSE), Ortalama Kare Hata Karekökü (RMSE), Ortalama Mutlak Hata (MAE) performans değerlendirme ölçütleri hataların tahmin sonuçları ise Çizelge 4. 2’de sunulmuştur.

Çizelge 4.2. ÇKYSA trainlm modelinin, çeşitli öğrenme algoritmaları ve farklı gizli katman nöron sayıları altında elde edilen başarı sonuçları.

Eğitim Fonksiyonuna Ait Bilgiler		Performans Ölçütü								
		Eğitim			Kontrol			Tahmin		
Eğitim Fonksiyon Tipi	öron Sayısı	MSE	MSE	AE	SE	MSE	AE	SE	MSE	AE
Trainlm	N = 5	0,0127	,1128	,0876	,0129	,1136	,0783	,0374	,1933	,1500
	N = 10	0,0124	,1115	,0863	,0108	,1040	,0730	,0301	,1734	,1321
	N = 15	0,0120	,1095	,0837	,0126	,1124	,0763	,0371	,1927	1451
	N = 20	0,0111	,1053	,0803	,0113	,1062	,0704	,0318	,1784	,1353
	N = 50	0,0095	,0973	,0736	,0113	,1064	,0778	,0388	,1971	,1461


Çizelge 4.2 'deki başarımların analizi sonucunda, başarımların analizi sonucunda, nöron sayılarımızın da 5 nöronlu yapının daha basit bir yapıya sahip olup yeterli gelmediğini 10 nöronlu yapı sinir ağının en verimli yapıya sahip olduğunu ve nöron sayısı arttıkça hatanın attığı elde edilmiştir. Trainscg (Levenberg-Marquardt) eğitim algoritmasının diğerlerine göre daha iyi performans gösterdiği tespit edilmiştir. Sinir ağının çok daha karmaşık yapı karşısında tepkisini kontrol etmek amacıyla 50 nöron sayısı gibi yüksek bir değer de verilerek tahmin kontrol edilmiş hatanın arttığı gözlemlenmiştir.

Trainlm (Levenberg-Marquardt) eğitim algoritmasının diğerlerine göre daha iyi performans gösterdiği tespit edilmiştir. Ayrıca, gizli katman sayısı 10 olarak belirlendiğinde, ağın eğitim aşamasında MAE değeri 0,0863, RMSE değeri 0,1115 ve MSE değeri 0,0124; tahmin aşamasında MAE değeri 0,1321, RMSE değeri 0,1734 ve

4. BULGULAR

MSE değeri 0,0301; doğrulama aşamasında ise MAE değeri 0,073, RMSE değeri 0,104 ve MSE değeri 0,0108 olarak kaydedilmiştir. Bununla birlikte, gizli katmandaki nöron sayısındaki değişikliklerin tahmin performansını etkilediği gözlemlenmiştir.

Şekil 4.4 'te, veri setindeki gerçek değerlerle tahmin edilen değerlerin ne derece örtüştüğü gösterilmektedir. Şekilde tahmin ön plana çıkarılıp kontrol edildiğinde doğru bir tahmin görülmektedir.



Şekil 4.4. Trainlm ÇKYSA tahmin ve gerçek değere göre grafiği

Şekil 4.4'te, veri setindeki gerçek değerlerle tahmin edilen değerlerin ne derece örtüştüğü gösterilmektedir. Bu şekilde grafik şeklinde yer verilerek diğer şekillerde dikkatimizi çekmeyen bir durum ortaya çıkmaktadır. Eğitim için verilen ocak ayının 25 ve 26. Günlerinde değerlerin birbirinden oldukça ters çalıştığı görülmekte olup tesisten

4. BULGULAR

edinilen bilgi neticesinde o günlerde bakım onarım nedeni ile çalışma yapıldığından üretim olmadığı bilgisi alınmıştır. Buda ÇKYSA doğru bir şekilde çalıştığını göstermektedir.

ÇKYSA Trainlm uygulamasından elde edilen sonuçları ile mevcut sonuçlar karşılaştırılmış Çizelge 4.3 yansıtılmıştır. Yapılan kontrolde Gerçek değerler ile tahmin edilen ederlerin birbirine yakın olduğu görülmektedir.

Çizelge 4.3. ÇKYSA trainlm uygulamasından elde edilen değerler


Aylar	Gerçek Değerler Aylık Ortalama	Trainlm Tahmin Değerleri Aylık Ortalama
1	0,291	0,371
2	0,549	0,556
3	0,577	0,526
4	0,765	0,730
5	0,585	0,554
6	0,758	0,770
7	0,652	0,674
8	0,702	0,750
9	0,621	0,637

4.1.2. Trainscg değerlendirme ölçütü

Trainscg (Scaled Conjugate Gradient), yapay sinir ağlarını eğitmek için kullanılan bir başka geri yayılım algoritmasıdır. Yapay sinir ağlarını eğitmek için kullanılan bir optimizasyon algoritmasıdır. Genellikle, backpropagation algoritmasının bir alternatifi olarak kullanılır ve daha hızlı bir yakınsama (convergence) sağlamak için tercih edilir. TrainSCG, Levenberg-Marquardt gibi bazı algoritmalara göre daha az hafıza gerektirir ve genellikle çok büyük veri setleri ve daha büyük ağlar için uygundur. Scaled Conjugate Gradient algoritması, Levenberg-Marquardt gibi daha karmaşık algoritmaların yerine daha az bellek kullanarak daha hızlı bir şekilde eğitim yapmayı sağlar. Genellikle büyük


4. BULGULAR

veri setleriyle çalışırken tercih edilir, çünkü daha düşük bellek tüketimi sağlar ve genellikle daha hızlı sonuç verir. Burada yapay sinir ağımızın eğitim, doğrulama, test ve tüm değerleri kontrol edilecektir.




Şekil 4.5. ÇKYSA trainscg 15 nöronlu tahmin sonuçları

Şekil 4.5 de tahmin edilen çıkış enerjisi değerleri ile sistemin gerçek çıkış değerlerinin ÇKYSA modeline göre eğitim, doğrulama, test ve tüm değerler bakımından aralarındaki ilişkiyi göstermektedir. Buna göre eğitim verileri için başarı oranı %88,463, doğrulama verileri için başarı oranı %88,868, test verileri için başarı oranı ise %88,288 olarak bulunmuştur. Ayrıca ağ yapısındaki tüm veriler için başarı oranı % 88,452 olarak bulunmuş olup bu değerler eğitilen ağın yeterince başarılı olduğunu ortaya koymaktadır.



Şekil 4.6. Trainscg hata dağılımı

Şekil 4.6, hata değerlerinin histogramını sunmaktadır. Yatay ekseninde hata değerleri (gerçek ile tahmin edilen değerler arasındaki fark) yer alırken, dikey ekseninde örnek sayıları gösterilmektedir. Şekilde hataların çoğunluğunun -0,03508 ile 0,06236 arasında dağıldığı, en yüksek hata değeri olan 0,011364'in ise belirgin bir yoğunluk gösterdiği gözlemlenmektedir.



Şekil 4.7. Trainscg Eğitim, test ve doğrulama verilerinin başarımlarındaki değişim

Şekil 4.7 her bir iterasyondaki eğitim, test ve doğrulama verilerine dayalı eğitim süresindeki başarımların değişimini göstermektedir. Modelin performans grafik incelendiğinde, en düşük hata değeri 15. iterasyonda elde edilmiştir.

Ayrıca, YSA modellerinin eğitim aşamasında aşırı öğrenme (overfitting) durumunun olup olmadığının kontrol edilmesi önemlidir. Bu kontrol, eğitim sürecinde eğitim ve doğrulama setlerindeki hata değerlerinin izlenmesiyle gerçekleştirilebilir. Eğitim iterasyonları sırasında test ve doğrulama hata eğrilerinin zıt yönlerde hareket etmesi istenmeyen bir durumdur ve bu, YSA eğitiminde istenilen başarıya ulaşamadığına işaret eder. Şekil 4.7'te, en iyi sonuç veren YSA eğitiminin hata kayıt grafik incelendiğinde, 15. iterasyonda eğitimin tamamlandığı anlaşılmaktadır. Grafikte yeşil daire ile gösterilen iterasyonda en düşük doğrulama hatası kaydedilmiştir. Test ve doğrulama hata vektörlerinin benzer bir eğilim gösterdiği gözlemlenmektedir. Bu durumda, oluşturulan YSA modelinin eğitim aşamasında aşırı öğrenme durumunun ortaya çıkmadığı sonucu çıkarılmaktadır.

Trainscg algoritmalarında nöron sayılarını belirlerken nöron sayılarının artırılması kullandığımız veriler doğrultusunda daha karmaşık yapılarda hangi nöron sayısı ile ne kadar doğru çalıştığını göstermektedir. Burada nöron sayılarını sıralı olarak artırarak öğrenmenin derecelerini ölçmek görmek isterken nöron sayılarını artırıp kontrol sağladık ilk başladığımız nöron sayısının 10 katını verip çok karmaşık yapılarda nasıl tahminde bulunacağını görmek istemiştir. 5, 10, 15, 20, 50 nöron sayıları kullanılarak

4. BULGULAR

elde edilen Ortalama Kare Hata (MSE), Ortalama Kare Hata Karekökü (RMSE), Ortalama Mutlak Hata (MAE) performans değerlendirme ölçütleri hataların tahmin sonuçları ise Çizelge 4. 4’de sunulmuştur.

Çizelge 4.4. ÇKYSA trainscg modelinin, çeşitli öğrenme algoritmaları ve farklı gizli katman nöron sayıları altında elde edilen başarı sonuçları.


Eğitim Fonksiyonuna Ait Bilgiler		Performans Ölçütü								
		Eğitim			Kontrol			Tahmin		
Eğitim Fonksiyon Tipi	Nöron Sayısı	MSE	MSE	AE	SE	MSE	AE	SE	MSE	AE
Trainscg	N = 5	0,0127	0,1128	0,0876	0,0129	0,1136	0,0783	0,0374	0,1933	0,1500
	N = 10	0,0124	0,1115	0,0863	0,0108	0,1040	0,0730	0,0301	0,1734	0,1321
	N = 15	0,0120	0,1095	0,0837	0,0126	0,1124	0,0763	0,0371	0,1927	0,1451
	N = 20	0,0111	0,1053	0,0803	0,0113	0,1062	0,0704	0,0318	0,1784	0,1353
	N = 50	0,0095	0,0973	0,0736	0,0113	0,1064	0,0778	0,0388	0,1971	0,1461

Çizelge 4.4 'deki başarımların analizi sonucunda, nöron sayılarımızın da 5 nöronlu yapının daha basit bir yapıya sahip olup yeterli gelmediğini 10 nöronlu yapı sinir ağının en verimli yapıya sahip olduğunu ve nöron sayısı arttıkça hatanın attığı elde edilmiştir. Trainscg (Levenberg-Marquardt) eğitim algoritmasının diğerlerine göre daha iyi performans gösterdiği tespit edilmiştir. Sinir ağının çok daha karmaşık yapı karşısında tepkisini kontrol etmek amacıyla 50 nöron sayısı gibi yüksek bir değer de verilerek tahmin kontrol edilmiş hatanın arttığı gözlemlenmiştir.

Ayrıca, gizli katman sayısı 15 olarak belirlendiğinde, ağın eğitim aşamasında MAE değeri 0,0823, RMSE değeri 0,1076 ve MSE değeri 0,0116 olmuştur. Tahmin aşamasında MAE değeri 0,1308, RMSE değeri 0,1741 ve MSE değeri 0,0303; doğrulama aşamasında ise MAE değeri 0,0721, RMSE değeri 0,1079 ve MSE değeri 0,0116 olarak kaydedilmiştir. Bununla birlikte, gizli katmandaki nöron sayısındaki değişikliklerin tahmin performansını etkilediği gözlemlenmiştir.

4. BULGULAR

Şekil 4.8 'te, veri setindeki gerçek değerlerle tahmin edilen değerlerin ne derece örtüştüğü gösterilmektedir. Şekilde tahmin ön plana çıkarılıp kontrol edildiğinde doğru bir tahmin görülmektedir.



Şekil 4.8. Trainscg ÇKYSA tahmin ve gerçek değere göre grafiği

Şekil 4.8'te, veri setindeki gerçek değerlerle tahmin edilen değerlerin ne derece örtüştüğü gösterilmektedir. Bu şekilde grafik şeklinde yer verilerek diğer şekillerde dikkatimizi çekmeyen bir durum ortaya çıkmaktadır. Eğitim için verilen ocak ayının 25 ve 26. Günlerinde değerlerin birbirinden oldukça ters çalıştığı görülmekte olup tesisten edinilen bilgi neticesinde o günlerde bakım onarım nedeni ile çalışma yapıldığından üretim olmadığı bilgisi alınmıştır. Buda ÇKYSA doğru bir şekilde çalıştığını göstermektedir.

4. BULGULAR


ÇKYSA Trainscg uygulamasından elde edilen sonuçları ile mevcut sonuçlar karşılaştırılmış Çizelge 4.5 yansıtılmıştır. Yapılan kontrolde Gerçek değerler ile tahmin edilen ederlerin birbirine yakın olduğu görülmektedir.

Çizelge 4.5. ÇKYSA trainscg uygulamasından elde edilen değerler

Aylar	Gerçek Değerler Aylık Ortalama	Trainscg Tahmin Değerleri Aylık Ortalama
1	0,291	0,368
2	0,549	0,555
3	0,577	0,513
4	0,765	0,755
5	0,585	0,561
6	0,758	0,772
7	0,652	0,649
8	0,702	0,733
9	0,621	0,618


4.1.3. Trainbr değerlendirme ölçütü

Trainbr (Bayesian Regularization), sadece hata fonksiyonunun (MSE) minimize edilmesiyle sınırlı değildir. Ayrıca, Bayesian Regularization kullanılarak ağırlıklar üzerinde bir düzenleme yapılır, bu da modelin aşırı öğrenme (overfitting) riskini azaltır ve daha genel bir model oluşturur. Eğitim sürecinde iterasyon sayısı, ağırlıkların büyüklüğü, doğrulama hatası gibi faktörler de algoritmanın başarısını değerlendirirken göz önünde bulundurulur. Yapay sinir ağlarını eğitmek için kullanılan bir algoritmadır ve Bayesian regularization tekniğini kullanarak ağırlık öğrenmesini iyileştirir. Bu algoritma, modelin overfitting (aşırı öğrenme) riskini azaltmak için regularization (düzenleme) yapar ve ağırlık genelleme kabiliyetini artırır. Trainbr genellikle doğruluk ve genelleme performansını optimize etmek için kullanılır.




Şekil 4.9. ÇKYSA trainbr 10 nöronlu tahmin sonuçları

Şekil 4.9 de tahmin edilen çıkış enerjisi değerleri ile sistemin gerçek çıkış değerlerinin ÇKYSA modeline göre eğitim, doğrulama, test ve tüm değerler bakımından aralarındaki ilişkiyi göstermektedir. Buna göre eğitim verileri için başarı oranı %86,87, doğrulama verileri için başarı oranı %93,131, test verileri için başarı oranı ise %89,128 olarak bulunmuştur. Ayrıca ağ yapısındaki tüm veriler için başarı oranı % 88,206 olarak bulunmuş olup bu değerler eğitilen ağın yeterince başarılı olduğunu ortaya koymaktadır.



Şekil 4.10. Trainbr hata dağılımı

Şekil 4.10 hata değerlerinin histogramını sunmaktadır. Yatay ekseninde hata değerleri (gerçek ile tahmin edilen değerler arasındaki fark) yer alırken, dikey ekseninde örnek sayıları gösterilmektedir. Şekilde hataların çoğunluğunun -0,03728 ile 0,05868 arasında dağıldığı, en yüksek hata değeri olan 0,0107'in ise belirgin bir yoğunluk gösterdiği gözlemlenmektedir.



Şekil 4.11. Trainbr eğitim, test ve doğrulama verilerinin başarımlarındaki değişim

Şekil 4.11 her bir iterasyondaki eğitim, test ve doğrulama verilerine dayalı eğitim süresindeki başarımların değişimini göstermektedir. Modelin performans grafik incelendiğinde, en düşük hata değeri 5. iterasyonda elde edilmiştir.

Ayrıca, YSA modellerinin eğitim aşamasında aşırı öğrenme (overfitting) durumunun olup olmadığının kontrol edilmesi önemlidir. Bu kontrol, eğitim sürecinde eğitim ve doğrulama setlerindeki hata değerlerinin izlenmesiyle gerçekleştirilebilir. Eğitim iterasyonları sırasında test ve doğrulama hata eğrilerinin zıt yönlerde hareket etmesi istenmeyen bir durumdur ve bu, YSA eğitiminde istenilen başarıya ulaşamadığına işaret eder. Şekil 4.11'te, en iyi sonuç veren YSA eğitiminin hata kayıt grafi incelendiğinde, 5. iterasyonda eğitimin tamamlandığı anlaşılmaktadır. Grafikte yeşil daire ile gösterilen iterasyonda en düşük doğrulama hatası kaydedilmiştir. Test ve doğrulama hata vektörlerinin benzer bir eğilim gösterdiği gözlemlenmektedir. Bu durumda, oluşturulan YSA modelinin eğitim aşamasında aşırı öğrenme durumunun ortaya çıkmadığı sonucu çıkarılmaktadır.

Trainbr algoritmaları nöron sayılarını belirlerken nöron sayılarının arttırılması kullandığımız veriler doğrultusunda daha karmaşık yapılarda hangi nöron sayısı ile ne kadar doğru çalıştığını göstermektedir. Burada nöron sayılarını sıralı olarak attırarak öğrenmenin derecelerini ölçmek görmek isterken nöron sayılarını arttırıp kontrol sağladık ilk başladığımız nöron sayısının 10 katını verip çok karmaşık yapılarda nasıl tahminde bulunacağını görmek istemiştir. 5, 10, 15, 20, 50 nöron sayıları kullanılarak elde edilen Ortalama Kare Hata (MSE), Ortalama Kare Hata Karekökü (RMSE), Ortalama Mutlak Hata (MAE) performans değerlendirme ölçütleri hataların tahmin sonuçları ise Çizelge 4.6'de sunulmuştur.


4. BULGULAR

Çizelge 4.6. ÇKYSA trainbr modelinin, çeşitli öğrenme algoritmaları ve farklı gizli katman nöron sayıları altında elde edilen başarı sonuçları.

Eğitim Fonksiyonuna Ait Bilgiler		Performans Ölçütü								
		Eğitim			Kontrol			Tahmin		
Eğitim Fonksiyonu Tipi	Nöron Sayısı	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE
Trainbr	N = 5	0,0127	0,1128	0,0876	0,0129	0,1136	0,0783	0,0374	0,1933	0,1500
	N = 10	0,0124	0,1115	0,0863	0,0108	0,1040	0,0730	0,0301	0,1734	0,1321
	N = 15	0,0120	0,1095	0,0837	0,0126	0,1124	0,0763	0,0371	0,1927	0,1451
	N = 20	0,0111	0,1053	0,0803	0,0113	0,1062	0,0704	0,0318	0,1784	0,1353
	N = 50	0,0095	0,0973	0,0736	0,0113	0,1064	0,0778	0,0388	0,1971	0,1461

Çizelge 4.6 'deki başarımların analizi sonucunda, başarımların analizi sonucunda, nöron sayılarımızın da 5 nöronlu yapının daha basit bir yapıya sahip olup yeterli gelmediğini 10 nöronlu yapı sinir ağının en verimli yapıya sahip olduğunu ve nöron sayısı arttıkça hatanın attığı elde edilmiştir. Trainscg (Levenberg-Marquardt) eğitim algoritmasının diğerlerine göre daha iyi performans gösterdiği tespit edilmiştir. Sinir ağının çok daha karmaşık yapı karşısında tepkisini kontrol etmek amacıyla 50 nöron sayısı gibi yüksek bir değer de verilerek tahmin kontrol edilmiş hatanın arttığı gözlemlenmiştir trainbr (Levenberg-Marquardt) eğitim algoritmasının diğerlerine göre daha iyi performans gösterdiği tespit edilmiştir. Ayrıca, gizli katman sayısı 10 olarak belirlendiğinde, ağın eğitim aşamasında MAE değeri 0,0851, RMSE değeri 0,1098 ve MSE değeri 0,0121; tahmin aşamasında MAE değeri 0,1358, RMSE değeri 0,1767 ve MSE değeri 0,0312; doğrulama aşamasında ise MAE değeri 0,0744, RMSE değeri 0,1117 ve MSE değeri 0,0125 olarak kaydedilmiştir. Bununla birlikte, gizli katmandaki nöron sayısındaki değişikliklerin tahmin performansını etkilediği gözlemlenmiştir.

Şekil 4.12 'te, veri setindeki gerçek değerlerle tahmin edilen değerlerin ne derece örtüştüğü gösterilmektedir. Şekilde tahmin ön plana çıkarılıp kontrol edildiğinde doğru bir tahmin görülmektedir.



Şekil 4.12. Trainbr ÇKYSA tahmin ve gerçek değere göre grafiği

Şekil 4.12’te, veri setindeki gerçek değerlerle tahmin edilen değerlerin ne derece örtüştüğü gösterilmektedir. Bu şekilde grafik şeklinde yer verilerek diğer şekillerde dikkatimizi çekmeyen bir durum ortaya çıkmaktadır. Eğitim için verilen ocak ayının 25 ve 26. Günlerinde değerlerin birbirinden oldukça ters çalıştığı görülmekte olup tesisten edinilen bilgi neticesinde o günlerde bakım onarım nedeni ile çalışma yapıldığından üretim olmadığı bilgisi alınmıştır. Buda ÇKYSA doğru bir şekilde çalıştığını göstermektedir.

ÇKYSA Trainbr uygulamasından elde edilen sonuçları ile mevcut sonuçlar karşılaştırılmış Çizelge 4.7 yansıtılmıştır. Yapılan kontrolde Gerçek değerler ile tahmin edilen ederlerin birbirine yakın olduğu görülmektedir.

Çizelge 4.7. ÇKYSA trainbr uygulamasından elde edilen değerler

Aylar	Gerçek Değerler Aylık Ortalama	Trainbr Tahmin Değerleri Aylık Ortalama
1	0,291	0,345
2	0,549	0,533
3	0,577	0,488
4	0,765	0,726
5	0,585	0,541
6	0,758	0,752
7	0,652	0,658
8	0,702	0,739
9	0,621	0,601

4.2. Uyarlamalı Bulanık Yapay Sinir Ağı Uygulaması (ANFIS)

Literatürde yöntemi geliştiren Jang tarafından tanıtılan ANFIS yöntemi, sınırlı sayıda girdi ile etkili bir çözüm sunmaktadır. Bu nedenle, girdi sayısının azaltılması, daha düşük hata oranlarıyla tahmin yapma imkanı sağlayabilir. (Doğan, 2016).


Özelliklerin sayısının yüksek olması, ANFIS uygulamasında hesaplama karmaşıklığını artırmaktadır. Bu nedenle, boyut azaltma işlemi için temel bileşenler analizi uygulanmıştır. Bu bağlamda, temel bileşenler analizi ile güneş enerjisi santrali çıkış enerjisini etkileyen 9 özellik, 3 özelliğe indirilmiştir. Diğer bir ifadeyle, problem üç girdi ve bir çıktıdan oluşan bir sistem haline getirilmiştir.

Kullanılan veriler en üst ve en alt kriter baz alınarak 0-1 aralığında sayısal değerlere çevrilmiştir. Kullanılan veri setinde 2022-2023 her güne ait değeri kullanıldı. 2024 yılındaki 274 günlük veri test amacı ile kullanılmıştır. Doğrulama için eğitim setinden rasgele seçilen %10'luk veri kullanılmıştır.

Kullanılan veriler anfis üzerinden üyelik fonksiyon tipi olarak trimf, trapmf, gbellmf, gaussmf, gauss2mf, pimf, dsigmf, psigmf olarak belirlenmiştir. Üyelik fonksiyon sayısı 2-2-2, 3-3-3 ve 4-4-4 olarak uygulanmaktadır. Çıkış üyelik fonksiyonları sabit ve doğrusal olarak seçilmiştir. Ortalama Kare Hata (MSE), Ortalama Kare Hata Karekökü (RMSE), Ortalama Mutlak Hata (MAE) hata değerleri üzerinden tahmin de bulunma işlemi yapılmıştır.


4.2.1. Anfis 2-2-2

Şekil 4.13 'de görüleceği üzere, mavi yuvarlak çizgiler eğitim verisi çıktılarını, kırmızı yıldızlar ise FIS çıktı değerlerini göstermektedir. Grafik dalgalı şekilde olması kışları düşen hava sıcaklığın ve güneşlenme süresine nedeni ile değişmektedir.




Şekil 4.13. ANFIS 2-2-2 modeli için uygulanan eğitim verilerinin yanıtları

Şekil 4.14'deki mavi noktalar, tahmin (testing) verilerine karşılık gelirken, kırmızı yıldızlar FIS modelinin çıktısını ifade etmektedir.



Şekil 4.14. ANFIS 2-2-2 modeli için uygulanan test verilerinin yanıtları


Şekil 4.15'deki mavi noktalar, kontrol (Checking) verilerine karşılık gelirken, kırmızı yıldızlar FIS modelinin çıktısını ifade etmektedir.



Şekil 4.15. ANFIS 2-2-2 modeli için uygulanan kontrol verilerinin yanıtları


Şekil 4.13, 4.14 ve 4.15’ye bakıldığında, elde edilen gerçek değerlerin tahmin edilen çıktı değerleri ile benzerlik gösterdiği dikkat çekmektedir.

Bu uygulamada, farklı sayıda üyelik fonksiyonu, tüm fonksiyon türleri ile birlikte constant/linear çıkış tipi için sistematik olarak test edilmiştir. Şekil 4.16 geliştirilen ANFIS modelinin yapısını göstermektedir. İlk aşamada üç bağımsız değişken girdi olarak sisteme dahil edilmiştir. İkinci aşamada, bu girdi değerleri 2-2-2 üyelik fonksiyonuna, belirli bir üyelik derecesi ile atanmıştır. Bir sonraki aşamada ise, üyelik fonksiyonları kullanılarak toplam 8 kural oluşturulmuştur. Bu 8 kural, bulanık ağın en etkili öğrenimi gerçekleştirmesi amacıyla belirlenmiş ve her bir kuraldan bir çıktı değeri üretilmiştir. Sonuç olarak, elde edilen çıktı üyelik fonksiyon değerleri, tek bir çıktı değerine indirgenmiştir.



Şekil 4.16. ANFIS 2-2-2 modeli ağ yapısı


Şekil 4. 17 kural editörünün giriş ve çıkış değerleri arasındaki ilişkiyi grafiksel olarak temsil ettiğini göstermektedir. Sol taraftaki üç sütun, giriş değerlerini simgelerken, sağ taraftaki sütun çıkış değerini belirtmektedir. Sütunlar üzerindeki kırmızı çizginin sağa veya sola hareket ettirilmesi, giriş değerlerinde değişiklik yapılmasını mümkün kılmakta ve bu değişiklikler neticesinde modelin çıkış değeri yeniden hesaplanabilmektedir.



Şekil 4.17. ANFIS 2-2-2 modeli için oluşturulan grafiği

4. BULGULAR


Şekil 4.18 sistemin eğitimin hastasını göstermektedir. Epochs sayısı artmasına karşın hata sabit kalmıştır.



Şekil 4.18. ANFIS 2-2-2 modeli eğitim hatası grafiği

Çizelge 4.8. ANFIS 2-2-2 yapıdaki üyelik fonksiyonları ile gerçekleştirilen denemelerden elde edilen başarı verileri.


Giriş Üyelik Fonksiyonuna Ait Bilgiler		Çıkış Üyelik Fonksiyonuna Ait Bilgiler	Performans Ölçütü								
			Eğitim			Kontrol			Tahmin		
Üyelik Fonksiyon Tipi	Üyelik Fonksiyon Sayısı	Üyelik Fonksiyon Tipi	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE
trimf	2-2-2	Sabit	0,0150	0,1225	0,0926	0,0115	0,1071	0,0726	0,0338	0,1838	0,1380
trapmf	2-2-2		0,0144	0,1198	0,0906	0,0111	0,1052	0,0717	0,0336	0,1832	0,1372
gbellmf	2-2-2		0,0142	0,1193	0,0905	0,0113	0,1064	0,0713	0,0340	0,1843	0,1385
gaussmf	2-2-2		0,0147	0,1211	0,0913	0,0111	0,1055	0,0708	0,0345	0,1856	0,1370
gauss2mf	2-2-2		0,0143	0,1197	0,0912	0,0110	0,1047	0,0698	0,0326	0,1805	0,1340
pimf	2-2-2		0,0142	0,1190	0,0907	0,0107	0,1034	0,0675	0,0322	0,1795	0,1344
dsigmf	2-2-2		0,0154	0,1241	0,0949	0,0120	0,1094	0,0712	0,0318	0,1783	0,1327
psigmf	2-2-2		0,0154	0,1241	0,0949	0,0120	0,1094	0,0712	0,0318	0,1783	0,1327
trimf	2-2-2	Doğrusal	0,0141	0,1188	0,0895	0,0107	0,1037	0,0684	0,0323	0,1798	0,1328
trapmf	2-2-2		0,0133	0,1155	0,0881	0,0113	0,1061	0,0727	0,0384	0,1960	0,1452
gbellmf	2-2-2		0,0130	0,1141	0,0872	0,0115	0,1071	0,0724	0,0334	0,1826	0,1358
gaussmf	2-2-2		0,0130	0,1142	0,0873	0,0114	0,1069	0,0721	0,0344	0,1854	0,1379
gauss2mf	2-2-2		0,0130	0,1138	0,0870	0,0115	0,1073	0,0717	0,0354	0,1881	0,1405
pimf	2-2-2		0,0128	0,1133	0,0865	0,0122	0,1106	0,0748	0,0352	0,1877	0,1401
dsigmf	2-2-2		0,0130	0,1140	0,0870	0,0120	0,1097	0,0737	0,0353	0,1878	0,1399
psigmf	2-2-2		0,0130	0,1140	0,0870	0,0120	0,1097	0,0737	0,0353	0,1878	0,1399



Şekil 4.19. ANFIS 2-2-2 modeli sonuçlara bağlı gerçek ve tahmin grafiği

4.2.2. Anfis 3-3-3


Şekil 4.20 'de görüleceği üzere, mavi yuvarlak çizgiler eğitim verisi çıktılarını, kırmızı yıldızlar ise FIS çıktı değerlerini göstermektedir. Grafik dalgalı şekilde olması kışları düşen hava sıcaklığın ve güneşlenme süresine nedeni ile değişmektedir.



Şekil 4.20. ANFIS 3-3-3 modeli için uygulanan eğitim verilerinin yanıtları


4. BULGULAR

Şekil 4.21 'deki mavi noktalar, tahmin (testing) verilerine karşılık gelirken, kırmızı yıldızlar FIS modelinin çıktısını ifade etmektedir.



Şekil 4.21. ANFIS 3-3-3 modeli için uygulanan test verilerinin yanıtları

Şekil 4.22'deki mavi noktalar, kontrol (Checking) verilerine karşılık gelirken, kırmızı yıldızlar FIS modelinin çıktısını ifade etmektedir.




Şekil 4.22. ANFIS 3-3-3 modeli için uygulanan kontrol verilerinin yanıtları

Şekil 4.20, 4.21 ve 4.22'ye bakıldığında, elde edilen gerçek değerlerin tahmin edilen çıktı değerleri ile benzerlik gösterdiği dikkat çekmektedir.

Bu uygulamada, farklı sayıda üyelik fonksiyonu, tüm fonksiyon türleri ile birlikte constant/linear çıkış tipi için sistematik olarak test edilmiştir. Şekil 4.23 geliştirilen ANFIS modelinin yapısını göstermektedir. İlk aşamada üç bağımsız değişken girdi olarak sisteme dahil edilmiştir. İkinci aşamada, bu girdi değerleri 3-3-3 üyelik fonksiyonuna, belirli bir üyelik derecesi ile atanmıştır. Bir sonraki aşamada ise, üyelik fonksiyonları kullanılarak toplam 27 kural oluşturulmuştur. Bu 27 kural, bulanık ağın en etkili öğrenimi gerçekleştirilmesi amacıyla belirlenmiş ve her bir kuraldan bir çıktı değeri üretilmiştir.

4. BULGULAR

Sonuç olarak, elde edilen çıktı üyelik fonksiyon değerleri, tek bir çıktı değerine indirgenmiştir.



Şekil 4.23. ANFIS 3-3-3 modeli ağ yapısı


Şekil 4. 24 kural editörünün giriş ve çıkış değerleri arasındaki ilişkiyi grafiksel olarak temsil ettiğini göstermektedir. Sol taraftaki üç sütun, giriş değerlerini simgelerken, sağ taraftaki sütun çıkış değerini belirtmektedir. Sütunlar üzerindeki kırmızıçizginin sağa veya sola hareket ettirilmesi, giriş değerlerinde değişiklik yapılmasını mümkün kılmakta ve bu değişiklikler neticesinde modelin çıkış değeri yeniden hesaplanabilmektedir.

4. BULGULAR



Şekil 4.24. ANFIS 3-3-3 modeli için oluşturulan grafiği

Şekil 4.25 sistemin eğitimin hastasını göstermektedir. Epochs sayısı artmasına karşın hata sabit kalmıştır.




Şekil 4.25. ANFIS 3-3-3 modeli Eğitim hatası grafiği

4. BULGULAR

Çizelge 4. 9. ANFİS 3-3-3 yapıdaki üyelik fonksiyonları ile gerçekleştirilen denemelerden elde edilen başarı verileri.


Giriş Üyelik Fonksiyonuna Ait Bilgiler		Çıkış Üyelik Fonksiyonuna Ait Bilgiler	Performans Ölçütü								
			Eğitim			Kontrol			Tahmin		
Üyelik Fonksiyon Tipi	Üyelik Fonksiyon Sayısı	Üyelik Fonksiyon Tipi	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE
trimf	3-3-3	Sabit	0,013	0,115	0,087	0,010	0,103	0,067	0,034	0,185	0,133
trapmf	3-3-3		0,012	0,112	0,086	0,010	0,103	0,068	0,038	0,195	0,141
gbellmf	3-3-3		0,012	0,111	0,085	0,010	0,104	0,070	0,032	0,180	0,134
gaussmf	3-3-3		0,013	0,116	0,088	0,010	0,103	0,068	0,033	0,182	0,133
gauss2mf	3-3-3		0,013	0,114	0,086	0,010	0,103	0,068	0,033	0,183	0,134
pimf	3-3-3		0,012	0,111	0,085	0,010	0,100	0,067	0,035	0,189	0,138
dsigmf	3-3-3		0,012	0,113	0,087	0,010	0,102	0,069	0,035	0,187	0,139
psigmf	3-3-3		0,012	0,113	0,087	0,010	0,102	0,069	0,035	0,187	0,139
trimf	3-3-3	Doğrusal	0,011	0,107	0,081	0,010	0,100	0,065	0,052	0,229	0,157
trapmf	3-3-3		0,011	0,108	0,082	0,009	0,099	0,067	1,016	1,008	0,312
gbellmf	3-3-3		0,011	0,105	0,080	0,009	0,098	0,067	0,166	0,408	0,186
gaussmf	3-3-3		0,011	0,106	0,081	0,009	0,094	0,063	0,080	0,283	0,174
gauss2mf	3-3-3		0,011	0,104	0,080	0,010	0,101	0,067	0,356	0,597	0,244
pimf	3-3-3		0,011	0,104	0,078	0,009	0,098	0,064	0,874	0,934	0,261
dsigmf	3-3-3		0,010	0,103	0,079	0,009	0,099	0,068	0,152	0,390	0,208
psigmf	3-3-3		0,010	0,103	0,079	0,009	0,099	0,068	0,152	0,390	0,208



Şekil 4.26. ANFİS 3-3-3 modeli sonuçlara bağlı gerçek ve tahmin grafiği


4.2.3. Anfis 4-4-4

Şekil 4.27 'de görüleceği üzere, mavi yuvarlak çizgiler eğitim verisi çıktılarını, kırmızı yıldızlar ise FIS çıktı değerlerini göstermektedir. Grafik dalgalı şekilde olması kışları düşen hava sıcaklığın ve güneşlenme süresine nedeni ile değişmektedir.



Şekil 4.27. ANFIS 4-4-4 modeli için uygulanan eğitim verilerinin yanıtları


Şekil 4.28'deki mavi noktalar, tahmin (testing) verilerine karşılık gelirken, kırmızı yıldızlar FIS modelinin çıktısını ifade etmektedir.



Şekil 4.28. ANFIS 4-4-4 modeli için uygulanan test verilerinin yanıtları

4. BULGULAR


Şekil 4.29'deki mavi noktalar, kontrol (Checking) verilerine karşılık gelirken, kırmızı yıldızlar FIS modelinin çıktısını ifade etmektedir.



Şekil 4.29. ANFIS 4-4-4 modeli için uygulanan kontrol verilerinin yanıtları

Şekil 4.27, 4.28 ve 4.29'ye bakıldığında, elde edilen gerçek değerlerin tahmin edilen çıktı değerleri ile benzerlik gösterdiği dikkat çekmektedir.


Bu uygulamada, farklı sayıda üyelik fonksiyonu, tüm fonksiyon türleri ile birlikte constant/linear çıkış tipi için sistematik olarak test edilmiştir. Şekil 4.30 geliştirilen ANFIS modelinin yapısını göstermektedir. İlk aşamada üç bağımsız değişken girdi olarak sisteme dahil edilmiştir. İkinci aşamada, bu girdi değerleri 4-4-4 üyelik fonksiyonuna, belirli bir üyelik derecesi ile atanmıştır. Bir sonraki aşamada ise, üyelik fonksiyonları kullanılarak toplam 64 kural oluşturulmuştur. Bu 64 kural, bulanık ağın en etkili öğrenimi gerçekleştirmesi amacıyla belirlenmiş ve her bir kuraldan bir çıktı değeri üretilmiştir. Sonuç olarak, elde edilen çıktı üyelik fonksiyon değerleri, tek bir çıktı değerine indirgenmiştir.



Şekil 4.30. ANFIS 4-4-4 modeli ağ yapısı grafiği


Şekil 4.31 kural editörünün giriş ve çıkış değerleri arasındaki ilişkiyi grafiksel olarak temsil ettiğini göstermektedir. Sol taraftaki üç sütun, giriş değerlerini simgelerken, sağ taraftaki sütun çıkış değerini belirtmektedir. Sütunlar üzerindeki kırmızıçizginin sağa veya sola hareket ettirilmesi, giriş değerlerinde değişiklik yapılmasını mümkün kılmakta ve bu değişiklikler neticesinde modelin çıkış değeri yeniden hesaplanabilmektedir.

4. BULGULAR



Şekil 4.31. ANFIS 4-4-4 modeli için oluşturulan grafiği

Şekil 4.32 sistemin eğitimin hastasını göstermektedir. Epochs sayısı artmasına karşın hata sabit kalmıştır.




Şekil 4.32. ANFIS 4-4-4 modeli Eğitim hatası grafiği

4. BULGULAR

Çizelge 4.10. 4-4-4 yapıdaki üyelik fonksiyonları ile gerçekleştirilen denemelerden elde edilen başarı verileri.

Giriş Üyelik Foknsiyonuna Ait Bilgiler		Çıkış Üyelik Foknsiyonuna Ait Bilgiler	Performans Ölçütü								
			Eğitim			Kontrol			Tahmin		
Üyelik Fonksiyon Tipi	Üyelik Fonksiyon Sayısı	Üyelik Fonksiyon Tipi	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE
trimf	4 4 4	Sabit	0,0123	0,1111	0,0841	0,0109	0,1042	0,0699	0,385	0,6207	0,2046
trapmf	4 4 4		0,0132	0,1148	0,0866	0,0098	0,0989	0,0641	0,047	0,2184	0,1542
gbellmf	4 4 4		0,0120	0,1097	0,0832	0,0097	0,0987	0,0660	0,290	0,5389	0,1970
gaussmf	4 4 4		0,0120	0,1096	0,0841	0,0097	0,0987	0,0650	0,104	0,3227	0,1835
gauss2mf	4 4 4		0,0118	0,1087	0,0828	0,0101	0,1003	0,0673	0,264	0,5138	0,2106
pimf	4 4 4		0,0128	0,1132	0,0853	0,0099	0,0996	0,0656	0,080	0,2838	0,1652
dsigmf	4 4 4		0,0120	0,1096	0,0830	0,0103	0,1015	0,0704	0,209	0,4580	0,2074
psigmf	4 4 4		0,0120	0,1095	0,0828	0,0104	0,1019	0,0701	0,087	0,2965	0,1724
trimf	4 4 4	Doğrusal	0,0092	0,0957	0,0717	0,0094	0,0967	0,0654	0,590	0,7684	0,2923
trapmf	4 4 4		0,0097	0,0986	0,0723	0,0080	0,0897	0,0610	2,903	1,7039	0,5508
gbellmf	4 4 4		0,0076	0,0874	0,0650	0,0090	0,0951	0,0630	1,747	1,3220	0,4304
gaussmf	4 4 4		0,0085	0,0921	0,0686	0,0091	0,0953	0,0629	3,884	1,9710	0,5273
gauss2mf	4 4 4		0,0091	0,0955	0,0712	0,0086	0,0926	0,0622	1,304	1,1419	0,4147
pimf	4 4 4		0,0088	0,0938	0,0695	0,0085	0,0923	0,0620	0,877	0,9367	0,3388
dsigmf	4 4 4		0,0078	0,0882	0,0655	0,0083	0,0909	0,0587	2,653	1,6289	0,4350
psigmf	4 4 4		0,0078	0,0882	0,0655	0,0083	0,0909	0,0586	2,646	1,6268	0,4344



Şekil 4.33. ANFIS 4-4-4 modeli sonuçlara bağlı gerçek ve tahmin grafiği

Çizelge 4.11. ANFIS ve ÇKYSA hata oranlarına göre karşılaştırılması

Yöntem		MSE	RMSE	MAE
ÇKYSA	Trainlm (N=10)	0,0301	0,1734	0,1321
	Trainscg (N=15)	0,0303	0,1741	0,1308
	Trainbr (N=10)	0,0312	0,1767	0,1358
ANFİS	Dsigmf (2 2 2)	0,0318	0,1783	0,1327
	Gbellmf (3 3 3)	0,0325	0,1804	0,1342
	Trapmf (4 4 4)	0,0477	0,2184	0,1542

Çizelge 4.11 hata durumları görülmektedir. Buna göre MSE göre en iyi model Trainlm (N=10), RMSE göre en iyi model Trainlm (N=10), Buna göre MAE göre en iyi model Trainscg (N=15) olarak görünmektedir.

5. SONUÇ ve ÖNERİLER

Güneş enerjisinin potansiyeli, diğer yenilenebilir enerji kaynaklarına kıyasla önemli ölçüde daha yüksektir; ancak bazı sınırlamalar bulunmaktadır. Güneş ışınımındaki dalgalanmalar ve iklim koşulları, fotovoltaik (FV) tesislerin enerji üretimini doğrudan etkilemektedir. Günümüzde, daha düşük maliyetli panellerin mevcut olması sayesinde güneş enerjisi, kademeli olarak modern enerji şebekelerine entegre edilmektedir. Fotovoltaik enerji kullanımındaki artış göz önüne alındığında, literatürde güneş enerjisi tahmini amacıyla yapay tekniklerden faydalanmak üzere çeşitli araçlar ve yaklaşımlar önerilmektedir. ANFIS ve ÇKYSA teknikleri ile elde ettiğimiz bulanık mantık mantık ve yapay sinir ağları ayrıca aşağıdaki gibi çeşitli alanlarda kullanabilmesi mümkündür.

Tahmin Doğruluğu: Gerçek değerler ile tahmin edilen değerler arasındaki yakınlık, modelin ne kadar iyi bir tahmin yaptığına işaret eder. Sinir ağı, meteorolojik veriler (girdi verileri) ile evirici gerilimleri (çıkış verileri) arasında güçlü bir ilişki kurmuştur. Bu, gelecekteki hava koşullarına bağlı olarak güneş enerjisi üretiminin doğru bir şekilde tahmin edilebileceğini gösterir.

Yüksek bir doğruluk, sistemin güneş enerjisi üretim tahmininde kullanılabilir olmasını sağlar.

Tahminlerin güvenilirliği, enerji santrallerinin üretim planlamasını optimize etmesine yardımcı olabilir.

Verimlilik ve Optimizasyon: Bu tahmin modeli sayesinde enerji santrallerinde daha iyi kaynak yönetimi ve üretim planlaması yapılabilir. Örneğin, bir güneş enerjisi santrali, gelecekteki güneşlenme sürelerine ve hava koşullarına göre üretim miktarını tahmin ederek kaynaklarını daha verimli kullanabilir.

Karar Verme Süreçlerini İyileştirme: Model sonuçları, santral yöneticilerinin daha bilinçli kararlar vermesine yardımcı olur. Örneğin: Üretim fazlası olduğunda, elektrik satışları optimize edilebilir.

Düşük üretim beklenen zamanlarda, enerji depolama sistemleri veya diğer enerji kaynakları devreye alınabilir.

Enerji Piyasasında Rekabet Gücü: Güneş enerjisi üretimi gibi yenilenebilir enerji kaynaklarının tahmin edilmesi, enerji piyasasında rekabet gücünü artırır.

Rüzgar Enerjisi Tahmini: Rüzgar hızına ve yönüne bağlı olarak rüzgar enerjisi santrallerinin üretim tahminleri yapılabilir. Meteorolojik veriler kullanılarak üretim planlaması optimize edilebilir.

Elektrik Talep Tahmini: Enerji talebi tahmininde, önceki talep verileri, hava durumu, mevsimsel faktörler ve ekonomik veriler gibi değişkenler kullanılarak talep tahmini yapılabilir. Bu da enerji sağlayıcıların üretim ve dağıtımını optimize etmesine yardımcı olur.

Finansal Tahminler: Sinir ağları ve yapay zeka yöntemleri, borsa, döviz kurları, hisse senedi fiyatları gibi finansal verilerde de kullanılır. Geçmiş finansal veriler, ekonomik göstergeler gibi bilgiler giriş olarak kullanılır ve gelecekteki piyasa fiyatları veya eğilimler tahmin edilebilir.

Hava Durumu Tahmini: Çok katmanlı yapay sinir ağları ve diğer yapay zeka yöntemleri, meteorolojik veriler kullanılarak kısa ve uzun vadeli hava durumu tahminlerinde kullanılabilir.

Endüstriyel Süreçlerin Kontrolü: Üretim tesislerinde sensör verileri kullanılarak, bir fabrikanın verimliliğini artıracak tahmin ve kontrol mekanizmaları oluşturulabilir. Bu, makinelerin bakım zamanlaması, enerji tüketimi ve üretim optimizasyonu gibi alanlarda faydalıdır.

Sağlık Alanı: Sinir ağları, hasta verileri kullanılarak teşhis ve tedavi tahminlerinde kullanılabilir. Örneğin, bir hastanın sağlık durumu, geçmiş tıbbi kayıtlarına ve diğer sağlık verilerine dayanarak tahmin edilebilir. Piyasa fiyatları tahminlerini ve enerji satışı stratejilerini optimize eder.

Ardahan ilindeki sıcaklık verilerinde, maksimum, minimum ve ortalama sıcaklık değerlerinde artış yönünde değişimler tespit edilmiştir. 2001-2003 dönemi ile karşılaştırıldığında, 2019-2021 döneminde bu sıcaklık değerleri sırasıyla %8.78, %24.50 ve %40.45 oranında yükselmiştir. 2001-2021 yılları arasındaki trend testi sonuçları, maksimum sıcaklıkların Haziran ayında, yaz mevsiminde ve yıllık bazda arttığını ortaya koymaktadır. Minimum sıcaklıklar ise Ekim ve Aralık aylarında, ilkbahar ve yaz mevsimlerinde ile yıllık değerde artış eğilimleri göstermektedir. Ortalama sıcaklık ise özellikle ilkbahar ve yaz aylarında ve yıllık toplamda artış göstermektedir (Kaltakkıran 2023).

Bu çalışma, meteorolojik verilere dayanarak bir güneş enerji santralinin enerji üretim tahminine dayalı bir yaklaşım sunmaktadır. Çalışmada, Göle Belediyesi Kurulu gücü 999 kW olan kapasiteli güneş enerji santraline ait üretim verileri kullanılmıştır. Tahmin algoritmaları olarak ÇKYSA ve ANFIS yöntemleri seçilmiştir. Algoritmaların sonuçları arasında karşılaştırmalı bir analiz gerçekleştirilmiştir.

Çalışmada da görüldüğü üzere Ardahan ili her geçen yıl GES potansiyeli açısından daha elverişli hale gelmesi, yanı sıra şehrin nüfus az olması nedeni ile yerleşimler yerlerinin az ve geniş araziler boş olması kullanılabilecek yerler bulunmaktadır. Göle belediyesi GES olarak inceleme yapıldığından 2022 yılı üretimleri 2023 yıl üretimleri karşılaştırıldığında bir artış görülmektedir. Belediyeler açısından GES bacasız fabrika niteliğinde yerelde maddi açıdan sıkıntılarını büyük ölçüde çözmekte olup enerji giderini yok etmekle kalmayıp fazla üretimlerde belediyeye ek gelir getirmektedir.

Çizelge 4.12. 2022-2023 yılları üretim karşılaştırması

2022-2023 KIYAS (Kwh)	
2022	1.506.960,80
2023	1.513.309,10

KAYNAKLAR

- Ardahan Afad www.ardahan.afad.gov.tr/kurumlar/ardahan.afad/e-kutuphane/Il-Planlari/Ardahan-IRAP.pdf Eriřim Tarihi: 06.05.2024.
- Ardahan Afad www.ardahan.afad.gov.tr/kurumlar/ardahan.afad/e-kutuphane/Il-Planlari/Ardahan-IRAP.pdf Eriřim Tarihi: 06.05.2024.
- Asma, B. (2022). Arazi tipi güneř enerji santrallerinin verimlilik analizi: Konya örneęi Konya teknik üniversitesi lisansüstü eğitim enstitüsü elektrik elektronik mühendislięi ana bilim dalı, Konya.
- Ayran, Z.A., 2019, Kütahya İli Güneř Enerji Potansiyelinin Arařtırılması Ve Örnek Bir Güneř Enerji Santralının Ekonomik Analizi, Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elektrik-Elektronik Mühendislięi Anabilim Dalı, Kütahya.
- Bachtır, R. E. (2002). Modeling of A Pumping Photovoltaic Station–Tracking of Optimal Operating Point. In International Forum on Renewable Energies FIER.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning, Springer, New York, NY.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- Carlson, R., Felnhofer, D., Rondeau, P., and Annakkage, U. (2002), Design And Construction Of A Maximum Power Tracking System For A Solar Panel, Course Number, 24.400.
- Cebeci, S. (2017). Türkiye’de Güneř Enerjisinden Elektrik Üretim Potansiyelinin Deęerlendirilmesi. T.C. Kalkınma Bakanlığı.
- Cořkun, C., Koçyięit, N., ve Oktay, Z. (2016). Estimation of Pv Modüle Surface Temperature Using Artificial Neural Netvorks. Muęla Journal Of Science And Technology, 2(2), 15-18.
- Çakmak, R., ve Altas, İ.H., (2016). Erzincan’da Güneř Enerjisinden Elektrik Üretimi Potansiyeli: Almanya İle Karřılařtırılması. Uluslararası Erzincan Sempozyumu Bildirileri, Erzincan.
- Çelebi, G. (2002). Bina Düşey Kabuęunda Fotovoltaik Panellerin Kullanım İlkeleri, Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 17(3), 17-33.
- Çınaroęlu, M.S.(2021). Kilis 7 Aralık Üniversitesinde Kurulacak Bir Ges Projesinin Pvsyst Aracılıęı ile Tasarım ve Analizi, Yüksek Lisans Tezi, Kilis 7 Aralık Üniversitesi, Lisansüstü Eğitim Enstitüsü, Kilis.
- Çiftçi, F., 2016, Güneř Enerji Sistemlerinde Farklı Cins Panellerle Maliyet Ve Güç Analizinin Yapılması, Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Enerji Ve Çevre Yönetimi Anabilim Dalı.

- Geçmez, A. ve Gençler, Ç. (2020). Güneş Enerji Santrali Üretim Verilerinin Meteorolojik Verilere Bağlı Olarak Yapay Zekâ Yöntemleri İle Tahmini. *International Studies on Natural and Engineering Sciences*, 2-37-51, Elazığ.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*, MIT Press, Cambridge, MA.
- Göle Kaymakamlığı <http://www.gole.gov.tr/genel-cografya-ve-yeryuzu-sekilleri> Erişim Tarihi: 22.10.2023.
- Güleç, G. H. ve Demirel, H. (2017). Meteorolojik Veriler Kullanılarak Kastamonu İli Güneşlenme Şiddetinin Yapay Sinir Ağları İle Tahmini. *Technological Applied Sciences*, 12(3), 114-121.
- H. H. Öztürk, “Güneş enerjisinden fotovoltaiik yöntemle elektrik üretiminde güç dönüşüm verimi ve etkili etmenler” Elektrik Tesisat Ulusal Kongre ve Sergisi Bildirileri, Adana, 2017.
- Hagan, M. T., & Menhaj, M. (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993.
- Hagan, M. T., Demuth, H. B., & Beale, M. (1996). *Neural Network Design*. PWS Publishing.
- Hamzaçebi, C. ve Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19, 227-233, Ankara.
- Haykin, S. (2009). *Neural Networks and Learning Machines*, Pearson, Upper Saddle River, NJ.
- İzmirli Ayan S. M. (2018) Fotovoltaiik sistemin yapay zeka algoritması ile güç tahmini Kırıkkale üniversitesi fen bilimleri enstitüsü enerji sistemleri mühendisliği anabilim dalı enerji sistemleri mühendisliği programı, Kırıkkale.
- Jang, J.-S. R., Sun, C.-T., & Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall.
- Kaynak: Göle Belediyesi Güneş Enerjisi Elektrik Üretim Santrali – YouTube Erişim Tarihi: 06.05.2024.
- Keskin, A., 2019, Niğde İli Güneş Enerji Santrali Modellemesi ve Performans Parametreleri Değerlendirmesi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Enerji Sistemleri Mühendisliği Ana Bilim Dalı, Niğde.
- Kılıcı, O., 2020, Değişken Özellikli Fotovoltaiik Güneş Enerji Santrallerinin Mevcut Verilerle PVsyst Programında Üretim ve Performans Analizi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Mekatronik Mühendisliği Ana Bilim Dalı.
- Kılınç, P.E (2019), 500 Kw’lık Güneş Enerjisi Panel Tasarımında Optimizasyon ve Ekonomik Analiz, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Fen

Bilimleri Enstitüsü, Isparta.

- Kınalı, M.Y., 2019, Güneş Enerjisi Simülasyon Programlarının Gerçek Verilerle Doğruluk Analizi, Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Makine Mühendisliği Ana Bilim Dalı, Enerji Sistemleri Mühendisliği Programı, Konya.
- Kocakuşak, R. (2018). Yenilenebilir Enerji Kaynaklarından Güneş Enerjisinin, Türkiye’deki Önemi Ve Ges Kurulum Araştırması (Yüksek Lisans Tezi). İstanbul Maltepe Üniversitesi, Sosyal Bilimleri Enstitüsü, İstanbul.
- Kutlu, S. (2002). Güneş Tarlası ile Elektrik Enerjisi Üretimi ve SDÜ Kampüs Alanında Bir Uygulama Analizi, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü. Makina Eğitimi Anabilim Dalı, Isparta.
- Lorenz, E., Hurka, J., Heinemann, D. ve Beyer, H. (2009). irradiance Forecasting for the Power Prediction of Grid-Connected Photovoltaic Systems. IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, 2(1), 2-10.
- Mellit, A. ve Kalogirou, S. (2008). Artificial intelligence techniques for photovoltaic applications: A review. Progress In Energy And Combustion Science, 34(5), 574-632, Cezayir.
- Özcan, İ. Şahin, Ş. A., Dikmen, E. ve Bayram, G. (2013). Isparta İlinde Rüzgâr Hızı Değerlerinin Belirlenmesi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 17(1), 109-112, Isparta.
- Özçelik, Ö., 2018, Güneş Enerji Sistemleri ve Güneş Yatırımları İçin Doğru Ve Güvenilir Bir Yol Haritası Oluşturulması, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elektrik Elektronik Mühendisliği Anabilim Dalı, Ankara.
- Özdemir Ali, T. (2022). Farklı Tipteki Fotovoltaik Sistemlerin Güç Üretimlerinin Analizi ve Yapay Zekaya Dayalı Tahmini. Düzce Üniversitesi 30-33, Düzce.
- Öztürk, H., 2021, Bir Güneş Enerji Santralinin Üretim ile Simülasyon Değerlerinin Karşılaştırılması ve Kayıp Analizi: Beştepe Enerji Örneği, Yüksek Lisans Tezi, Hasan Kalyoncu Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Bilimleri ve Enerji Yönetimi Anabilim Dalı, Gaziantep.
- Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. In Proceedings of the IEEE International Conference on Neural Networks.
- Sağlam, F. (2022) Malatya’da Bulunan Güneş Enerji Santrallerine Ait Üretim Verilerinin Analiz Edilmesi. İnönü Üniversitesi Fen bilimleri Enstitüsü, Malatya.
- Savaş, S. Duraklar, K. Çınar, O. Koç, M. Turan, A. Uslu, U. Doğanay, A. Özceyhan, O. Destan, M. ve Duşbudak, H. Bilişim Sistemleri ve Yönetim Araştırmaları Dergisi Güneş Enerjisi Sistemlerinde Yenilikçi ve Akıllı Bakım Onarım <https://dergipark.org.tr/en/download/article-file/2796731> Erişim Tarihi: 15.08.2024.
- Somuncu, S. (2023) Amasya Üniversitesi Güneş Enerji Santrali Üretim Verilerinin

Meteorolojik Verilere Bağlı Olarak Yapay Zeka Yöntemleri İle Tahmini, Amasya Üniversitesi Fen Bilimleri Enstitüsü, Amasya.

- Şahin, S. (2019) Güneş enerji santrallerinin verimlerine eden faktörlerin değerlendirmesi, Amasya üniversitesi fen bilimleri enstitüsü, Amasya.
- Şahin, S., 2019, Güneş Enerji Santrallerinin Verimlerine Etki Eden Faktörlerin Değerlendirilmesi, Amasya Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Yenilenebilir Enerji ve Uygulamaları Ana Bilim Dalı, Amasya.
- T.C. Enerji ve Tabii Kaynaklar Bakanlığı “Elektrik” T.C. Enerji ve Tabii Kaynaklar Bakanlığı, Haziran 21, 2022. [Çevrimiçi]: <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik> Erişim Tarihi: 01.08.2022.
- T.C. Enerji ve Tabii Kaynaklar Bakanlığı “Elektrik” T.C. Enerji ve Tabii Kaynaklar Bakanlığı, Haziran 21, 2023. <https://gepa.enerji.gov.tr/MyCalculator/pages/75.aspx> Erişim Tarihi: 01.03.2023.
- Takagi, T., & Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 15(1), 116–132.
- Teiaş Türkiye Elektrik Üretim iletim 2022 yılı istatistikleri <https://www.teias.gov.tr/turkiye-elektrik-uretim-iletim-istatistikleri> Erişim Tarihi: 13.01.2024.
- Tunçgövdü, K.(2020). İzmir İlinde Bulunan Binalarda Elektrik Üretimi İçin Kullanılan Fotovoltaik Güneş Panel Tiplerinin Verimlilik Bakımından Karşılaştırılması ve Maliyet Analizi, Yüksek Lisans Tezi, Manisa Celal Bayar Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Yalçın, Ö. (2019) Kazımkaabekir, Korkuteli ve Aksaray Bölgelerindeki Güneş Enerji Santrallerinin İklim Koşullarına Göre Performans Değerlendirilmesi Karamanoğlu Mehmetbey üniversitesi Fen Bilimleri Enstitüsü, Karaman.
- Yalçın, Ö. (2019) Kazımkarabekir, Korkuteli ve Aksaray bölgelerindeki güneş enerji santrallerinin iklim koşullarına göre performans değerlendirilmesi karamanoğlu Mehmetbey üniversitesi fen bilimleri enstitüsü, Karaman.
- Yeşilkaya, M. A. (1998). Güneş Pillerinin Mikroişlemci ile Konum Kontrolünün Tasarımı ve Gerçekleştirilmesi. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Yıldız, A. (2003). Fotovoltaik Modüllerin Binalarda Kullanımı ve PVSYST 3.21 Yazılımı ile Bir Binanın Simülasyonu, Yayımlanmış yüksek lisans tezi, Gazi Üniversitesi Fen Bilimleri, Ankara.