

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

YSA TABANLI GÜN ÖNCESİ SAATLİK GÜNEŞ IŞINIM KESTİRİMİ

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Müh. Sibel ÇEVİK

**OCAK 2018
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK- ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YSA TABANLI GÜN ÖNCESİ SAATLİK GÜNEŞ IŞINIM KESTİRİMİ

Elektrik- Elektronik Müh. Sibel ÇEVİK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
" ELEKTRİK YÜKSEK MÜHENDİSİ "
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 02 / 01 / 2018

Tezin Savunma Tarihi : 25 / 01 / 2018

Tez Danışmanı : Prof. Dr. İsmail Hakkı ALTAŞ

Trabzon 2018

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Elektrik-Elektronik Anabilim Dalında
Sibel ÇEVİK tarafından hazırlanan**

YSA TABANLI GÜN ÖNCESİ SAATLİK GÜNEŞ IŞINIM KESTİRİMİ

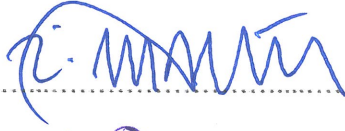
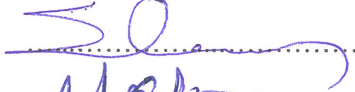

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 02 / 01 / 2018 gün ve 1734 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Prof. Dr. İsmail Hakkı ALTAŞ

Üye : Prof. Dr. Ertuğrul ÇAM

Üye : Prof.Dr. Murat EKİNCİ

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Yenilenebilir enerji kaynaklarından elektrik üretimi her geçen gün artmaktadır. Güneş ve rüzgâr gibi yenilenebilir enerji kaynaklarının elektrik şebekesine entegrasyonunda bu kaynakların kesintili karakteristiği nedeniyle birtakım problemler meydana gelmektedir. Elektrik şebekesinin kararlı bir şekilde çalışmasını sağlamak için kesintili ve değişken karakteristiğe sahip olan yenilenebilir enerji kaynaklarından yapılacak olan üretimin doğru tahmin edilmesi gerekmektedir. Güneş ışınım verisi de doğrudan fotovoltaik (FV) güç ile ilişkilidir. FV güç sistemi çalışmalarının yapılacağı ve ölçülmüş FV güç verisi olmayan bölgeler için FV güç kestirimi, güneş ışınımı kestirimi ile mümkün olabilmektedir. Saatlik güneş ışınım kestirimi probleminin çözümü için, k-medoids kümeleme algoritması ve yapay sinir ağları yaklaşımı kullanılmıştır.

Bu tez çalışması süresince, tezin amacına ulaşması için bana yol gösteren gerek bilimsel çalışmalarında gerekse diğer konularda beni destekleyen ve yardımcı olan tez danışmanım Prof. Dr. İsmail Hakkı ALTAŞ'a ilgi ve desteğinden dolayı teşekkürlerimi saygı ve minnetle sunarım.

Bu tez çalışması, TÜBİTAK EEEAG-115E943 numaralı projesi kapsamında yapılan çalışmalardan üretilmiştir. Projede burs desteği sağladığı için TÜBİTAK'a teşekkür ederim.

Ayrıca bu tez çalışmasında ve projeye alakalı diğer işlerde bilgisiyle her zaman çalışmalarına yardımcı olan Arş. Gör. Recep ÇAKMAK'a teşekkür ederim.

Çalışmalarım süresince beni destekleyen, hiçbir konuda yardımlarını esirgemeyen Arş. Gör. Yeşim Aysel BAYSAL'a ve yol arkadaşım Hakan BEKTAŞ'a yanımda oldukları için teşekkür ederim. Son olarak bu tez çalışmasının ülkemize faydalı olması temennisi ile annem Fatma ÇEVİK'e ithaf ediyorum.

Sibel ÇEVİK
Trabzon 2018

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Yapay Sinir Ağları Tabanlı Gün Öncesi Saatlik Güneş Işınım Kestirimi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. İsmail Hakkı ALTAŞ‘ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 25/01/2018

Sibel ÇEVİK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY.....	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ.....	XII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Literatür Araştırması.....	2
1.3. Güneş ve Güneş Işınımı.....	5
1.3.1. Yatay Eksene Toplam Güneş Işınımı.....	5
1.3.2. Güneş Açıları.....	6
1.3.2.1. Enlem Açısı (φ).....	6
1.3.2.2. Deklinasyon Açısı(δ).....	7
1.3.2.3. Saat Açısı (w).....	8
1.3.3. Yatay Düzleme Gelen Atmosfer Dışı Güneş Işınımı.....	8
1.3.4. Saatlik Açıklık İndeks Hesabı.....	9
1.4. K-Medoids Kümeleme Algoritması.....	9
1.5. Küme Geçerliliği Teknikleri.....	10
1.5.1. Silhouette İndeksi.....	11
1.6. Yapay Sinir Ağları.....	11
1.6.1. Biyolojik Sinir Hücresi.....	12
1.6.2. Yapay Sinir Hücresi.....	12
1.6.3. Çok Katmanlı Yapay Sinir Ağı Modeli.....	14
1.6.4. Yapay Sinir Ağları Parametrelerinin Belirlenmesi.....	16
1.6.4.1. Katman Sayısının ve Nöron Sayılarının Belirlenmesi.....	16
1.6.4.2. Aktivasyon Fonksiyonu.....	17

1.6.4.3.	Veri Normalleştirme.....	17
1.6.4.4.	Eđitim ve Test Kumesi.....	18
1.6.4.5.	Tahminin Doğruluđunu Deđerlendirme Ölçütleri.....	18
1.6.5.	Yapay Sinir Ağlarında Öğrenme.....	19
1.6.6	Yapay Sinir Ağlarının Eđitilmesi.....	20
1.6.6.1	Geri Yayılım Algoritması.....	21
2.	YAPILAN ÇALIŞMALAR.....	26
2.1.	Giriş	26
2.2.	Güneş Işınımı Kestirimi İçin Verilerin Düzenlenmesi.....	26
2.2.1.	Trabzon İlinin Saatlik Güneş Işınım Verisi.....	28
2.2.2.	Saatlik Açıklık İndeks Hesabı.....	30
2.2.3.	Günlük Açıklık İndeks Hesabı.....	32
2.3.	Verilerin Kümelenmesi.....	33
2.3.1.	Verilerin Mevsimlere Göre Düzenlenmesi.....	35
2.3.2.	K-Medoids Algoritması ile Verilerinin Kümelenmesi.....	35
2.4.	Gün Öncesi Saatlik Güneş Işınımı Verisinin Tahmin Edilmesi İçin Tasarlanan Sistemin Genel Yapısı.....	38
2.5.	Önerilen Yöntemin Uygulanması ve Sonuçlar.....	40
2.5.1.	Kış Mevsimi Ağları.....	40
2.5.2.	İlkbahar Mevsimi Ağları.....	45
2.5.3.	Yaz Mevsimi Ağları.....	49
2.5.4.	Sonbahar Mevsimi Ağları.....	53
2.6.	Önerilen Yöntemin Diđer Çalışmalarla Karşılaştırılması.....	57
3.	SONUÇLAR VE TARTIŞMA.....	58
4.	ÖNERİLER.....	60
5.	KAYNAKLAR.....	61

ÖZGEÇMİŞ

Yüksek Lisans Tezi

ÖZET

YSA TABANLI GÜN ÖNCESİ SAATLİK GÜNEŞ IŞINIM KESTİRİMİ

Sibel ÇEVİK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Anabilim Dalı
Danışman: Prof. Dr. İsmail Hakkı ALTAŞ
2018, 64 Sayfa

Yenilenebilir enerji kaynaklarından elektrik üretimi her geçen gün artmakta ve bu kaynakların elektrik şebekesine entegrasyonunda bu kaynakların kesintili karakteristiği nedeniyle birtakım problemler meydana gelmektedir. Elektrik şebekesinin kararlı bir şekilde çalışmasını sağlamak için kesintili ve değişken karakteristiğe sahip olan yenilenebilir enerji kaynaklarından yapılacak olan üretimin doğru tahmin edilmesi gerekmektedir. Güneş ışınım verisi de doğrudan fotovoltaik (FV) güç ile ilişkilidir. FV güç sistemi çalışmalarının yapılacağı ve ölçülmüş FV güç verisi olmayan bölgeler için FV güç kestirimi, güneş ışınımı kestirimi ile mümkün olabilmektedir. Bu tez çalışması kapsamında, FV güç sistemi çalışmalarının kararlı bir şekilde çalışmasını sağlamak ve akıllı şebekede yapılacak olan yük planlama çalışmalarına katkı sağlamak amacıyla gün öncesi saatlik güneş ışınım kestirimi yapılmıştır. Trabzon iline ait geçmiş yılların saatlik güneş ışınımı verisi kullanılarak gün öncesinden ertesi günün saatlik güneş ışınım verisi yapay zeka yöntemlerinden yapay sinir ağları (YSA) yaklaşımı ile kestirilmiştir. Güneş ışınım verisi analiz edilerek mevsimsel olarak ayrıştırılarak k-medoids algoritması ile kümeleme işlemine tabi tutulmuştur. Kümeleme işlemi sonucunda günler hava tipine göre açık, bulutlu ve yağmurlu olmak üzere üç farklı sınıfa ayrılmıştır. Her bir sınıf için farklı bir yapay sinir ağı tasarlanmıştır. Tasarlanan YSA modeli, MATLAB benzetim programında MATLAB'nin YSA araç kutusunda bulunan kodlar kullanılmadan tasarlanmış, eğitilmiş ve test edilmiştir. Yapılan kestirimlerin doğruluğu çeşitli performans ölçütleri ile değerlendirilmiştir.

Anahtar Kelimeler: Güneş enerjisi, kestirim, güneş ışınım kestirimi, yapay sinir ağları, Trabzon

Master Thesis

SUMMARY

A DAY AHEAD HOURLY SOLAR IRRADIATION FORECASTING WITH ANN

Sibel ÇEVİK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Prof. Dr. İsmail Hakkı ALTAŞ
2018, 64 Pages

Electricity generation from renewable energy sources is increased day by day and integration of renewable energy sources to the electrical grid leads to some issues in the grid because of intermittent and variable characteristics of these renewable energy sources. Accurate forecasting of electricity generation from the renewable energy sources which have intermittent and variable characteristics is a requirement to ensure stable operation of the electrical grid. Solar irradiation data is also directly associated with photovoltaic (FV) power. FV power forecasting for areas with PV power system studies and without measured PV power data, can be made possible by solar irradiation forecasting. In this thesis, day ahead hourly solar irradiation forecasting has been made to ensure the work of the PV power system in a stable operation and contribute to the load planning work in the smart grid. The next day hourly solar irradiation data for the province of Trabzon have been forecasted by artificial neural network (ANN) approach using one day ahead hourly solar irradiation from the past years. The solar irradiation data is analyzed by a seasonal separation and classified by k-medoids algorithm. As a result of the clustering process, days are divided into three different classes by air type: clear, cloudy and rainy. A different artificial neural network is designed for each class. The designed ANN model has been designed, trained and tested in MATLAB simulation environment without using codes of the MATLAB ANN toolbox. The accuracy of the predictions has been evaluated by different performance measures.

Key Words—Solar energy, forecast, solar irradiation forecast, artificial neural networks, Trabzon

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1.	Yatay eksene gelen doğrudan ve yaygın ışınım.....6
Şekil 1.2.	Deklinasyon açısı.....7
Şekil 1.3.	Saatler ve açı karşılıkları.....8
Şekil 1.4.	Yapay sinir hücre modeli.....13
Şekil 1.5.	Çok katmanlı yapay sinir ağı yapısı.....15
Şekil 1.6.	Eğitim akış şeması.....21
Şekil 2.1.	Verilerin düzenlemesi için gerekli adımlar.....27
Şekil 2.2.	Yatay düzleme gelen saatlik güneş ışınımı verisi29
Şekil 2.3.	1 Ocak-5 Ocak tarihleri arasında yatay düzleme gelen saatlik güneş ışınımı.....30
Şekil 2.4.	Atmosfer dışına gelen saatlik güneş ışınımı verisi.....31
Şekil 2.5.	1-5 Ocak 2015 tarihleri arasında atmosfer dışına gelen saatlik güneş ışınımı.....32
Şekil 2.6.	Günlük açıklık indeks verileri.....33
Şekil 2.7.	Örnek açık, bulutlu ve yağmurlu günlerin güneş ışınım verileri.....34
Şekil 2.8.	2015 yılı kış mevsimi için yapılan kümeleneş örnek veriler.....37
Şekil 2.9.	Sistemin genel yapısı (örnek: kış mevsimi).....38
Şekil 2.10.	Tasarlanan yapay sinir ağı modeli.....40
Şekil 2.11.	Kış mevsimi açık günler (YSA1) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....42
Şekil 2.12.	Kış mevsimi bulutlu günler (YSA2) test kümesinin gerçek ve kestirilmiş güneş ışınım değerleri.....43
Şekil 2.13.	Kış mevsimi yağmurlu günler (YSA3) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....44
Şekil 2.14.	İlkbahar mevsimi açık günler (YSA4) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....46
Şekil 2.15.	İlkbahar mevsimi bulutlu günler (YSA5) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....47

Şekil 2.16.	İlkbahar mevsimi yağmurlu günler (YSA6) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....	48
Şekil 2.17.	Yaz mevsimi açık günler (YSA7) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....	50
Şekil 2.18.	Yaz mevsimi bulutlu günler (YSA8) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....	51
Şekil 2.19.	Yaz mevsimi yağmurlu günler (YSA9) test kümesinin gerçek ve kestirilmiş güneş ışınım değerleri.....	52
Şekil 2.20.	Sonbahar mevsimi açık günler (YSA10) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....	54
Şekil 2.21.	Sonbahar mevsimi bulutlu günler (YSA11) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....	55
Şekil 2.22.	Sonbahar mevsimi yağmurlu günler (YSA12) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri.....	56

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 2.1. Trabzon ili için mevsimlere göre hesaplanan günlük ortalama güneş ışınım şiddeti.....	28
Tablo 2.2. Aylar ve mevsimleri.....	35
Tablo 2.3. Kümeleme işlemleri ile belirlenmiş günler, sayıları ve Silhouette indeks değerleri.....	36
Tablo 2.4. YSA'lar için giriş ve çıkış verileri.....	39
Tablo 2.5. Kış mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları.....	40
Tablo 2.6. Kış Mevsimi YSA'ları eğitim ve test seti hataları.....	41
Tablo 2.7. İlkbahar mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları.....	45
Tablo 2.8. İlkbahar mevsimi YSA'ları eğitim ve test seti hataları.....	45
Tablo 2.9. Yaz mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları.....	49
Tablo 2.10. Yaz Mevsimi YSA'ları eğitim ve test seti hataları.....	49
Tablo 2.11. Sonbahar mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları.....	53
Tablo 2.12. Sonbahar Mevsimi YSA'ları Eğitim ve test seti hataları.....	53

SEMBOLLER DİZİNİ

I_t	Toplam ışınım
I_d	Doğrudan ışınım
I_y	Yaygın ışınım
G_{sc}	Güneş sabiti
K	Sınıf sayısı
D	n tane eleman içeren veri seti
TC_{ih}	Toplam maliyet değişimi
KOH	Karesel ortalama hata
OMYH	Ortalama mutlak yüzde hata
KOHK	Karesel ortalama hatanın karekökü
R	Korelasyon katsayısı
OMH	Ortalama mutlak hata

1. GENEL BİLGİLER

1.1. Giriş

Dünyadaki fosil yakıtların sınırlı olması, bu kaynakların giderek azalması ve kullandıklarında çevreye zarar vermeleri nedeniyle yenilenebilir enerji kaynaklarına yönelim, zorunlu hale gelmiştir. Güneş enerjisi temiz bir enerji kaynağı olup en çok tercih edilen yenilenebilir enerji kaynaklarından biridir. Yenilenebilir enerji kaynaklarından elektrik üretiminde yıllık olarak en fazla artışın güneş enerjisi ile elektrik üretiminde olacağı öngörülmektedir [1]. Güneş enerjisinden elektrik üretiminde kullanılan fotovoltaik (FV) panellerinin fiyatlarının azalması ve yenilenebilir enerji kaynaklarından elektrik üretimine verilen devlet teşvikleri sonucunda FV sistemlerin kurulumu her geçen yıl artmaktadır [2].

Yenilenebilir enerji kaynakları değişken güç üretim karakteristiğine sahiptir. Güneş enerjisi ile elektrik üretiminde sıcaklık, bağıl nem, rüzgâr hızı, hava basıncı ve yağış miktarı gibi iklimsel değişiklikler üretilen FV güçte dalgalanmalara sebep olmaktadır. FV sistemler kontrol edilmediğinde bu dalgalanmalar, sistemin kararlılığını etkilemektedir [2].

Güvenilir ve ekonomik çalışma için FV güç sistemi çalışmaları, gerçek zamanlı, bir gün önceden, haftalık, aylık ve yıllık planlanır. Güvenilir ve kararlı bir elektrik şebekesi oluşturmak için FV sistemlerden yapılacak olan elektrik enerjisi üretim miktarının doğru tahmin edilmesi gerekmektedir. Ayrıca gün öncesi elektrik piyasası için üretilecek gücün doğru tahmini elektrik gücünün ticareti açısından oldukça önemlidir.

Elektrik şebekesinin kararlılığının sağlanması, yenilenebilir enerji kaynaklarından yapılan üretimlerin elektrik şebekesine entegrasyonu ve elektrik tüketiminde oluşan tepe tüketimlerin meydana getirdiği sorunların çözümü için akıllı şebeke çalışmaları başlamıştır [3]. Yenilenebilir enerji kaynaklarından yapılacak olan üretimin tahmin edilmesi akıllı şebekede yapılacak olan yük planlama çalışmalarına [4, 5] fayda sağlayacaktır. FV güç tahminleri doğrudan ve dolaylı olmak üzere iki şekilde yapılmaktadır. Güneş ışınım verisi de doğrudan FV güç ile ilişkilidir. FV güç sistemi çalışmalarının yapılacağı ve ölçülmüş FV güç verisi olmayan bölgeler için FV güç tahmini, güneş ışınımı tahmini ile mümkün olabilmektedir.

Bu tez çalışması kapsamında, FV güç sistemi çalışmalarının kararlı bir şekilde çalışmasını sağlamak ve akıllı şebekede yapılacak olan yük planlama çalışmalarına katkı sağlamak amacıyla gün öncesi yatay eksene gelen saatlik toplam ortalama güneş ışınım kestirimi yapılmıştır. Trabzon iline ait geçmiş yılların saatlik güneş ışınımı verisi kullanılarak gün öncesinden ertesi günün saatlik güneş ışınım verisi yapay zeka yöntemlerinden yapay sinir ağları (YSA) yaklaşımı ile kestirilmiştir.

1.2. Literatür Araştırması

Güneş ışınımı tahmini/kestiriminde genel olarak dört yöntem kullanılmaktadır [6]. Bunlar; istatistiksel yaklaşım (ARMA, ARIMA, ARMAX vb.) [7], fiziksel yaklaşım [8], yapay zekâ [9], ve hibrit model yöntemleridir [10, 11]. Gün öncesi saatlik güneş ışınım kestirimi çalışmaları genellikle ulusal hava tahmini (National Weather Prediction, NWP) verileri kullanılarak yapılmaktadır[12].

Mellit ve Pavan (2010), gün öncesi saatlik güneş ışınım tahmini yaptıkları çalışmalarında, günlük ortalama güneş ışınım ve sıcaklık değerlerini giriş, sonraki günün 24 saatlik güneş ışınım değerlerini çıkış olarak kullanarak çok katmanlı yapay sinir ağı tasarlamışlardır. Ağın eğitimini geri yayılım algoritması ile yapmışlardır ve güneş ışınım tahmini yaptıktan sonra tahmini gücü de hesaplayarak ölçülen güç değeri ile karşılaştırmışlardır. İki değer birbirine uygunluğunu -korelasyon katsayısı- ile ifade edilen sonuçlara göre güneşli günde yaklaşık %98 bulutlu günde ise yaklaşık %95 olarak elde etmişlerdir [13].

Ding (2011) ve arkadaşları gün öncesi yarım saatlik FV güç tahmini yaptıkları çalışmalarında, tahmin gününün ortalama, minimum ve maksimum sıcaklık değerlerine göre tahmin gününe benzeyen gün seçimi yapmışlardır. Benzer gün ile tahmin gününün maksimum, minimum ve ortalama sıcaklık değerleri ile benzer günün yarım saatlik güneş ışınım değerlerini giriş olarak kullanarak çok katmanlı yapay sinir ağı tasarlamışlardır. Ağ geri yayılım algoritması ile eğiterek ağın performansını ortalama mutlak yüzde hata performans ölçütüne göre değerlendirmişlerdir [14].

Grimaccia (2012) ve arkadaşları, FV enerji üretimini tahmin etmek amacıyla yaptıkları çalışmalarında bulanık mantık ve yapay sinir ağı kullanılmışlardır. Günün sabah, öğle, akşam bölümlerinde ultraviyole indeksi ve bulutluluk değerlerine göre bulanık mantık yöntemi ile ön ışınım tahmini yapmışlardır. Bu ışınım değerlerini ve günün her bölümü için

nem, rüzgâr hızı, bulutluluk ve basınç değerlerini ayrı ayrı girişler kabul ederek çok katmanlı yapay sinir ağı oluşturmuşlardır. Ağı geri yayılım algoritması ile eğitim tahminin doğruluğunu ortalama hata ile hesaplanmışlardır [15].

Ferrari (2013) ve arkadaşları, saatlik güneş ışıınım tahmini yaptıkları çalışmalarında, sayısal zekâ yöntemlerinden destek vektör makineleri (Support Vector Regression, SVR) ve aşırı öğrenme makinesi (Extreme Learning Machine, ELM) kullanmışlardır. Hava istasyonundan alınan tarihsel ışıınım değerlerini ve sıcaklık değerlerini kullanarak zaman serileri oluşturmuşlardır. Tahminin doğruluğunu ortalama mutlak hata yüzdesi ile hesaplanmışlardır. Destek vektör makineler sayısal zekâ yöntemi ile yapılan tahmin aşırı öğrenme makinesine göre daha doğru olmuştur ancak öğrenme süresinin daha uzun olduğunu göstermişlerdir [16].

Yang (2013) ve arkadaşları, kısa dönem güneş ışıınım tahmini yaptıkları çalışmalarında, tarihsel veriler ile tahmini sıcaklık verisi kullanarak öklit normu ile benzer gün seçimi yapmışlardır. Benzer günler ile destek vektör makineleri (DVM) yöntemini kullanarak kısa dönem güneş ışıınım tahmini yapmışlardır. Ayrıca çalışmalarına dalgacık ayırıştırma yöntemini eklemeleri sayesinde de güneş ışıınım tahmini yaparak bu iki tahmin değerini karşılaştırmışlardır. Hibrit yapı ile daha doğru güneş ışıınım tahmini yapıldığını ifade etmişlerdir [17].

Baharin (2014) ve arkadaşları, kısa dönem saatlik güneş ışıınım tahmini yaptıkları çalışmalarında, tarihsel güneş ışıınımı verisini kullanarak destek vektör makineleri yöntemi ile kestirim yapmışlardır. Buna ek olarak, yapay sinir ağları yöntemi ile de güneş ışıınım tahmini yapmış ve bu iki yöntemi karşılaştırmışlardır. Destek vektör makineleri yöntemi ile yapay sinir ağları yöntemine göre daha doğru tahmin yapıldığını ifade etmişlerdir [18].

Yan (2014) ve arkadaşları, güneş ışıınım tahmini yaptıkları çalışmalarında kestirim yapılacak güne ait meteorolojik tahmin istasyonundan elde edilen saatlik sıcaklık ve nem tahminlerini kullanarak yapay sinir ağı yaklaşımı ile gün öncesi saatlik güneş ışıınımı kestirimi yapmışlardır [19].

Gandelli ve arkadaşları (2014), gün öncesi saatlik enerji üretim tahmini yapmak için temel fiziksel ve yapay sinir ağlarıyla oluşturulan, fiziksel ve YSA yöntemlerini birleştiren hibrit, (Physical Hybridized Artificial Neural Network, PHANN) modelini analiz etmişlerdir. Çalışmada, gün, saat, sıcaklık, rüzgar hızı, nem, basınç ve bulutluluk verileri ile çok katmanlı yapay sinir ağı yapısı oluşturulmuş ve ağ, geri yayılım algoritması ile eğitilmiştir. Yapılan tahminin doğruluğu için; normalize ortalama mutlak hata (nOMH),

ortalama mutlak hatanın ağırlığı (aOMH) ve normalize karesel ortalama hatanın karekökü (nKOHK) performans ölçütleri kullanılmıştır [20].

Abuella ve Chowdhury (2015) gün öncesi saatlik FV güç tahmini yapmak amacıyla yüzey basıncı, nem, bulutluluk, rüzgâr hızı, sıcaklık, güneş ışınımı gibi girişler kullanarak çeşitli yapay sinir ağları tasarlamışlardır. Yapay sinir ağları ile yapılan tahmin istatistiksel modeller ile yapılan tahminlerle karşılaştırmışlardır. Yapay sinir ağları ile yapılan tahminin istatistiksel modellere göre daha doğru sonuçlar verdiği tespit etmişlerdir [21].

Watetakarn ve Premrudeepreechacharn (2015) gün öncesi yarım saatlik güneş ışınım değerinin tahminini yaptıkları çalışmalarında çok katmanlı yapay sinir ağı tasarlamışlardır ve ağı, geri yayılım algoritması ile eğitmişlerdir. Ağın girişleri, önceki günün yarım saatlik ışınımı, sıcaklık, nem, yağış miktarı ve havanın bulutluluk durumu iken çıkışları istenilen günün belirlenen zaman aralığındaki yarım saatlik güneş ışınım değerleridir [22].

Li (2015) ve arkadaşları FV enerji üretimini gün öncesinden saatlik tahmin etmek amacıyla yaptıkları çalışmalarında, tarihsel veri ve ilgili günün hava tahmini kullanılarak havanın durumuna göre (güneşli, bulutlu, yağmurlu) aynı tipteki her saat için ayrı yapay sinir ağı kurmuşlardır ve ağı aşırı öğrenme makinesi (Extreme Learning Machine, ELM) öğrenme algoritması ile eğitilmişlerdir. Bu metotla yapılan tahmin klasik geri yayılım algoritması ile karşılaştırılmıştır ve üç hava durumuna göre de ELM algoritması ile daha doğru tahminler yapılmıştır [23].

Ceylan (2015) ve arkadaşları gün öncesi saatlik güneş ışınımının kestirimi için yaptıkları çalışmalarında geçmiş günlere ait güneş ışınımı verisi ve tahmin gününün meteorolojik tahmini bulut kapalılığı verisini kullanarak regresyon tabanlı bir hesaplama yöntemi kullanmışlardır [24].

Huang (2015) ve arkadaşları gün öncesi FV güç üretimini kestirmek amacıyla yaptıkları çalışmalarında günleri beş farklı hava tipine ayırmışlardır. Daha doğru tahmin yapmak için, farklı hava tiplerine yönelik oluşturulan ağlardan en uygunu bulanık mantık yöntemiyle belirlenmiştir [25].

Moustris (2016) ve arkadaşları, gün öncesi saatlik güneş ışınım tahmini için çok katmanlı bir yapay sinir ağı modeli önermiştir. Bu ağda, giriş olarak yılın günü, günün saati, tahmin gününden önceki günün 24 saatlik sıcaklık, nem ve güneş ışınım verileri çıkış olarak ise, tahmin günü için 24 saatlik güneş ışınım verisi kullanılmıştır [26].

Rana (2016) ve arkadaşları ertesi gün için yarım saatlik FV güç tahmini yaptıkları çalışmalarında, tahmin günü için tahmini maksimum, minimum ve ortalama güneş ışınımı, sıcaklık, nem ve rüzgâr hızı verileri kullanarak sinir ağı tasarlamışlardır [27].

Türkiye’de güneş ışınım tahmini için aylık [28, 29], günlük [30], anlık [31] ve saatlik çalışmalar [32, 33] yapılmıştır.

Akarslan ve Hocoğlu (2016) çalışmalarında, verileri mevsimsel olarak ayrıştırıp yaz ve kış verileri için lineer tahmin, diğer mevsimler için ise deneysel yöntem kullanarak güneş ışınım tahmini yapmışlardır [32].

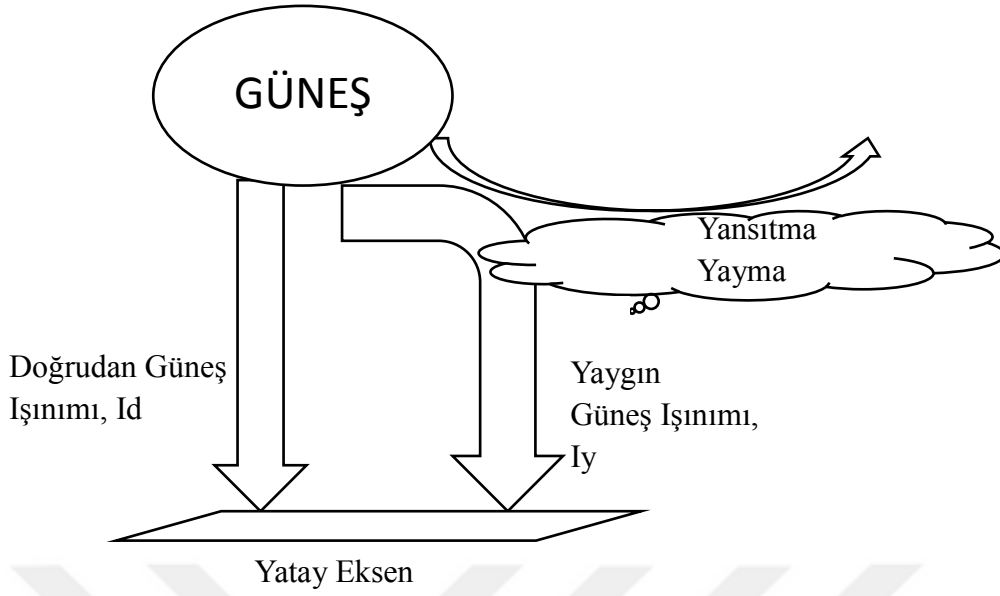
Hocoğlu ve Serttaş (2017) güneş ışınımı verisinin kendini tekrarladığı kabulüyle, Mycielski-Markov hibrit modeli ile saatlik güneş ışınımı verisine geçmişte en çok benzeyen en uzun güneş ışınımı serisini bularak saatlik güneş ışınımı tahmini yapmışlardır [33].

1.3. Güneş ve Güneş Işınımı

Güneş yoğun sıcak gazlar içeren 1.39×10^9 m çapında dünyadan ortalama 1.5×10^{11} m uzaklıkta olan bir küredir. Yüzeyinde 577 K olan sıcaklık değeri merkeze doğru 4×10^6 ile 8×10^6 K arasında değişim göstermektedir. Güneşten gelen radyan enerji çeşitli füzyon reaksiyonlara uğramaktadır. Güneş yüzeyindeki yüksek sıcaklık nedeniyle elektronların atom çekirdeklerinden ayrılmasına bağlı olarak güneş yüzeyinde serbest elektron ve atom çekirdekleri bulunur. Dört hidrojen çekirdeği füzyon adı verilen reaksiyon ile çok yüksek sıcaklıkta birleşerek helyum çekirdeğini oluşturur. Güneşte oluşan helyum miktarı harcanan hidrojen miktarına oranla daha azdır. Aradaki fark güneş ışınımı ile oluşan enerjiyi belirtir. Ortaya çıkan enerji çeşitli dalga boylarındaki ışınlar halinde dünyaya ulaşmaktadır [34].

1.3.1. Yatay Eksene Toplam Güneş Işınımı

Yeryüzüne ulaşan toplam güneş ışınımı, doğrudan ve yaygın olmak üzere ikiye ayrılır. Atmosferdeki toz ve bulutlar nedeniyle saçılan güneş ışınımına yaygın ışınım, hiçbir etkiye uğramadan ulaşan ışınlarla ise doğrudan ışınım denir. Şekil 1.1’de yatay eksene gelen doğrudan ve yaygın ışınım gösterilmiştir.



Şekil 1.1. Yatay eksene gelen doğrudan ve yaygın ışınım

Herhangi bir yatay eksene gelen toplam ışınım (I_t), doğrudan (I_d) ve yaygın (I_y) olmak üzere eşitlik (1.1)'de gösterilmiştir. Yatay eksene gelen toplam ışınım değeri piranometre cihazı ile ölçülmektedir. Birimi W/m^2 'dir [35].

$$I_t = I_d + I_y \quad (1.1)$$

Bu çalışmada, yatay eksene gelen saatlik güneş ışınım verisi kestirimi yapılmıştır.

1.3.2. Güneş Açıları

Güneş enerjisi uygulamalarında çeşitli hesaplamalar yapmak için güneş açlarına ihtiyaç duyulmaktadır. Bu tez çalışmasında, atmosfer dışına gelen saatlik güneş ışınım verisi hesabı yapmak için güneş açılarından yararlanılmıştır.

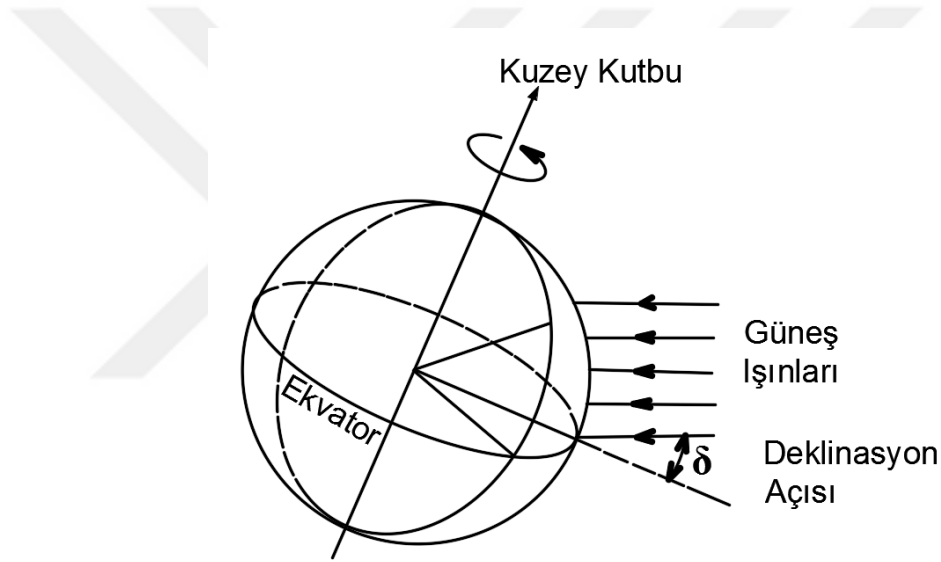
1.3.2.1. Enlem Açısı (ϕ)

Yeryüzündeki herhangi bir noktayı dünya merkezine birleştiren doğrunun; dünyanın ekvator düzlemi ile yaptığı açıdır. Ekvatorun kuzey yönünde her bir enlem pozitif, güney

yönündeki her bir enlem negatif değer alır. Kuzey kutbunda enlem değeri $+90^{\circ}$, güney kutbunda -90° 'dir. Türkiye, $36-42^{\circ}$ kuzey enlemleri arasında yer alır. Trabzon ilinin enlem açısı ise $+41^{\circ}$ 'dir.

1.3.2.2. Deklinasyon Açısı (δ)

Güneş ışınlarının ekvator düzlemi ile yaptığı açıdır. Şekil 1.2'de deklinasyon açısı gösterilmiştir. Deklinasyon açısı, dünyanın kendi eksenini ve yörünge düzlemi ile yaptığı $23,45$ derecelik açıdır.




Şekil 1.2. Deklinasyon açısı

Bu açı, $-23,45^{\circ} \leq \delta \leq 23,45^{\circ}$ açıları arasında yıl boyunca değişir. En yüksek değerini 21 Haziran, en küçük değerini ise 21 Aralık gününde alır. Ekinoks tarihlerinde ise bu değer 0 derecedir. Deklinasyon açısının yaklaşık değeri Cooper denklemi ile hesaplanır. "n", bir Ocaktan itibaren gün sayısı olmak üzere Cooper denklemi eşitlik (1.2)'de gösterilmiştir.

$$\delta = 23,45 \times \sin[(360/365) \times (284+n)] \quad (1.2)$$

1.3.2.3. Saat Açısı (ω)

Güneş ışınlarının bulunduğu boylam ile göz önüne alınan yerin boylamı arasındaki açıdır. Saat açısı, güneş boylamının göz önüne alınan yerin boylamı ile kesiştiği güneş öğlesinden önce ise (-), sonra ise (+) olarak alınır. Güneş öğlesinde, güneş saati (GS)12'dir. Güneş öğle vakti ile ilgili zaman arasındaki saat farkı, 15 sabit sayısı ile çarpılarak güneş saat açısı bulunur. Bu sabit sayı, dünyanın güneş çevresinde 1 saatte yaptığı açıdır. Saat açısının her bir saat için gösterimi Şekil 1.3'te gösterilmiştir.



Şekil 1.3. Saatler ve açı karşılıkları

Güneş öğlesine göre simetriktir olan güneş açıları eşitlik (1.3)'te verilen denklem ile hesaplanmaktadır.

$$\omega = 15 \times (\text{GS}-12) \quad (1.3)$$

1.3.3. Yatay Düzleme Gelen Atmosfer Dışı Güneş Işınımı

Yatay düzleme herhangi bir anda gelen güneş ışınımı değeri günlerin saatlik açıklık indekslerinin hesaplanması için gereklidir. Belirli saatler arasında yatay düzleme gelen toplam güneş ışınımı eşitlik (1.5)'te gösterilmiştir. Eşitlikte w_2 saat açısı w_1 saat açısından büyük olmalıdır [36]. G_{sc} , güneş sabitidir ve değeri 1367 W/m^2 'dir. Eşitlik (1.4)'te hesaplanan f , n yılın gününe bağlı olarak değişen düzeltme faktörüdür [37].

$$f = (1 + 0.033 \cos \frac{360n}{365}) \quad (1.4)$$

$$I_0 = \frac{12 \times 3600}{\pi} \times G_{sc} \times f \times [\cos \varphi \cdot \cos \delta (\sin w_2 - \sin w_1) + \frac{\pi(w_2 - w_1)}{180} \sin \varphi \cdot \sin \delta] \quad (1.5)$$

Atmosfer dışına gelen saatlik güneş ışınımının birimi, J/m^2 'dir. Yapılan hesaplamalar için bu birim eşitlik (1.6) ile W/m^2 'ye dönüştürülmüştür.

$$1kW=360kJ \quad (1.6)$$

1.3.4. Saatlik Açıklık İndeks Hesabı

Saatlik açıklık indeks hesabı, yatay düzleme bir saatlik periyotta gelen toplam güneş ışınımının aynı saatler arasında atmosfer dışına gelen toplam güneş ışınımına oranı ile hesaplanmaktadır. Yatay düzleme bir saatlik periyotta gelen toplam güneş ışınımını, I ve atmosfer dışına gelen saatlik toplam güneş ışınımı I_0 olmak üzere saatlik açıklık indeks hesabı eşitlik (1.7)'de gösterilmiştir.

$$K_t = \frac{I}{I_0} \quad (1.7)$$

1.4. K-Medoids Kümeleme Algoritması

Kaufman ve Rousseuw (1987) tarafından geliştirilen k-medoids algoritması, farklı özellikteki verileri k adet temsilci nesne bularak sınıflandıran kümeleme yöntemlerinden birisidir. Kümenin merkezine en yakın nokta, temsilci nesne olarak adlandırılan medoiddir. K-medoids yöntemi ile k adet temsilci nesne belirlendikten sonra geriye kalan nesnelere kendilerine en yakın temsilciye atanarak k adet küme oluşturulur. Nesne ile ait olduğu kümenin temsilci nesnesi arasında ortalama benzersizlik maliyet fonksiyonu kullanılarak kümenin kalitesi yükseltinceye kadar her bir temsilci nesne temsilci olmayan nesne ile değiştirilir. Bu bölünme metodu, her bir nesne ve onun referans noktası arasındaki benzersizliklerin toplamının küçültülmesini amaçlayarak kümeleme yapar.

K-medoids algoritmasında yapılandırma ve deęiřtirme ařamalarından oluřur. Yapılandırma ařamasında k adet temsilci nesne seilir. Deęiřtirme ařamasında ise kmeleme iřleminin verimi arttırılana dek bu temsilci nesnelere temsilci olmayan bařka nesnelere ile deęiřtirilir.

Giriřler:

k : sınıf sayısı

D : n tane eleman ieren veri seti

ıkıř: k adet sınıf seti.

Algoritma adımları:

Adım 1: Bařlangı k adet hedef nesne rastgele seilir

Adım 2: Kalan her nesne en yakın olduęu medoid'in kmesine atanır.

Adım 3: Medoid olmayan rastgele bir nesne seilir, $O_{rastgele}$.

Adım 4: O_j medoid'i ile $O_{rastgele}$ 'nin deęiřimi iin toplam maliyet, TC_{ih} hesaplanır.

Adım 5: Eęer $TC_{ih} < 0$ ise O_j ve $O_{rastgele}$ deęiřtirilerek medoid kmesi yenilenir.

Adım 6: Hibir deęiřim olmayıncaya kadar ikinci adıma geri dnlr [38].

1.5. Kme Geerlilięi Teknikleri

Kme geerlilięi teknikleri kmeleme analizinin sonularının kalitesini deęerlendirmek iin kullanılır. Silhouette indeksi, Calinski ve Harabazs indeksi, Krzanowski ve Lai indeksi bu teknikler arasındadır. Bu indeksler kme ii deęiřim ve kmeler arası deęiřim lleri arasındaki iliřkilere dayanmaktadır. İyi bir kmelemede, aynı kme ierisinde yer alan birimler arasındaki benzerlięin mmkn olduka fazla, farklı kme ierisinde yer alan birimler arasındaki benzerlięin ise olabildięince az olması hedeflenir.

1.5.1. Silhouette İndeksi

Rousseuw (1987), her bir birimin kendi kümesine uygunluğunu tanımlayacak bir Silhouette indeksi önermiştir. $a(i)$; i . birimin kendi kümesindeki tüm noktalara olan ortalama uzaklıklarını (benzerliğini) ve $b(i)$; i . birimin diğer kümelerdeki tüm noktalara olan ortalama uzaklıkların minimumunu gösterir. Buradan i . birim için Silhouette indeksi eşitlik (1.8)'de gösterilmiştir;

$$sil(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (1.8)$$

olarak tanımlanır. Eğer $sil(i)$ değeri 1'e yaklaşırsa i . birimin atandığı kümeye daha uyduğu, $sil(i)$ değeri 0'a yaklaşırsa veya negatif olursa i . birimin atandığı kümeye uygun olmadığı sonucuna varılır. Negatif değerler yalnızca bir birim en uygun kümesine atanmadığında ortaya çıkar. Tüm kümelemenin kalitesi (geçerliliği) için bir doğal bir ölçü eşitlik (1.9)'deki şekilde hesaplanır;

$$sil(C) = \frac{1}{n} \sum_{s_i \in S} sil(i) \quad (1.9)$$

$Sil(C)$ tüm birimler için ortalama Silhouette değeri olarak tanımlanabilir [39]. Silhouette endeksinin 0.5'ten büyük olması veri setini ayırdığımız küme sayısının yeterli, 0.2'den küçük olması veri setini ayırdığımız küme sayısının doğal küme sayısını karşılamadığını göstermektedir [40].

1.6. Yapay Sinir Ağları

Yapay sinir ağları canlıların beyninin ve sinir sisteminin matematiksel olarak basit bir şekilde modellenmiş halidir. Bu ağlar bilgisayar ağlarına benzer şekilde çalışırlar ancak bilgisayarlarda yapılan programlardan farklı olarak belirli bir işi yerine getirmenin yanı sıra sınıflandırma, genelleme, optimizasyon yapma ve öğrenme gibi özellikleri vardır. Elde ettikleri verileri değerlendirerek birbirleriyle olan bağıntılarını, ilişkilerini ve örüntülerini başarılı bir şekilde öğrenebilirler.

Endüstriyel alanda artan makineleşmeye bağlı olarak makinelerin dışarıdan müdahale edilmeksizin akıllı birer varlık gibi karar verebilmesine ihtiyaç duyulması ve insan beyninin gerçekleştirdiği düşünme, öğrenme ve yeni olaylara tepki vererek uyum sağlama yeteneklerinin matematiksel olarak ifade edilip edilemeyeceği sorusu birçok araştırmacının ilgisini çekerek yapay sinir ağlarının matematiksel olarak modellenmesinde birer etmen olmuştur. Yapılan modelleme sayesinde dışarıdan müdahale olmaksızın kendi kendine öğrenen ve karar verebilen yapılar ortaya çıkmıştır.

Yapay sinir ağları günümüzde insan beyninin sahip olduğu işlevselliğe henüz ulaşamamış olsalar da birçok alanda başarılı şekilde kullanılmaktadır. Yapay sinir ağları, kendisi için özel olarak uyarlanmış devreler ya da bilgisayar programları sayesinde kullanılacağı alanla uyumlu hale getirilebilirler.

Yapay sinir ağına dair birçok model olmakla birlikte modellerin temelini oluşturan nöron yapısı hemen hemen aynıdır. Modelleri birbirinde ayıran noktalar ise nöronların bağlantı kurma biçimleri, yapay sinir ağının öğrenme algoritması, nöronların giriş ve çıkış sinyalleri arasındaki ilişkidir.

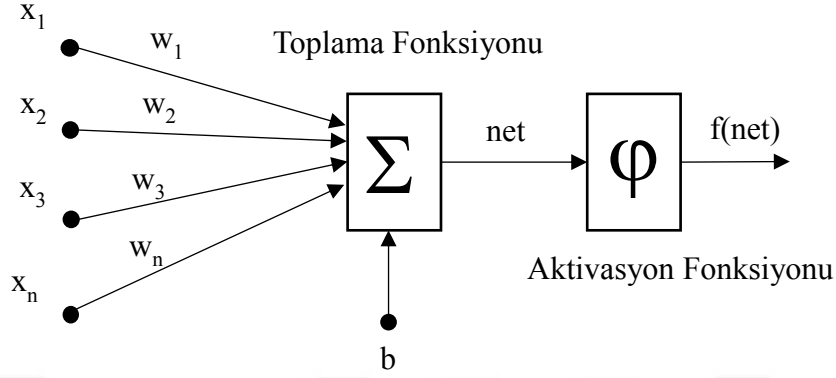
1.6.1. Biyolojik Sinir Hücresi

Beyin bilgiyi alan, yorumlayan ve karar üreten bir yapı olarak biyolojik sinir sisteminin merkezini oluşturmaktadır. Beyindeki sinir ağları, nöron olarak adlandırılan milyarlarca sinir hücresi içermektedir. Nöronlar dentrit, akson, çekirdek ve bağlantılar olmak üzere dört ana yapıdan oluşmaktadır. Ağaç kökü görünümüne sahip olan dentritler, bağlı oldukları diğer nöronlardan gelen sinyalleri çekirdeğe iletmektedir. Çekirdek ise, dentritten gelen sinyalleri toplayarak aksona iletir. Toplanan bu sinyaller akson tarafından işlenerek, üretilen yeni sinyallerin diğer nöronlara iletilmesi için bağlantılara gönderilir.

1.6.2. Yapay Sinir Hücresi

Biyolojik nöronlarda olduğu gibi, yapay nöronlar da giriş bilgilerini aldıkları, bu sinyalleri toplayıp işledikleri ve çıktılarını ürettikleri bölümlerden oluşurlar. Yapay sinir ağlarının en temel hücresi olan yapay sinir hücresi girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı bölümlerinden oluşmaktadır. Bir veya birden fazla giriş alan

nöronlar tek çıkış üretirler ve bu çıktı değeri diğer nöronlar için girdi değeri veya ağ çıkış sonucu olabilir. Yapay bir sinir hücre modeli Şekil 1.4'te gösterilmiştir.



Şekil 1.4. Yapay sinir hücre modeli

Girişler: Giriş değerleri, dış dünyadan ya da diğer nöronlardan hücreye aktarılan bilgilerdir. Her bir nöron bir veya daha fazla girdi değeri alabilir. Şekil 1.4'te gösterilen $x_1, x_2, x_3, \dots, x_n$ değerleri girdileri ifade etmektedir. Dış dünyadan gelen girdi değerleri ağırlık öğrenmesi istenilen örneklerle belirlenirler.

Ağırlıklar: Yapay sinir ağı içerisindeki tüm girdi nöronlar arasında bağlantılar ağırlıklar ile sağlanır. Nörona girilen girdi değerlerinin sinir hücresi üzerindeki etkisini belirleyen uygun katsayılar, ağırlıkları oluşturur. Ağırlıklar yapay sinir ağının bilgisini saklayan katsayılardır. Şekil 1.2'de $w_1, w_2, w_3, \dots, w_n$ değerleri ağırlıkları ifade etmektedir.

Toplama Fonksiyonu: Bir hücreye gelen net girdiyi hesaplayan bir fonksiyon olan toplama fonksiyonu, genellikle her bir giriş değeri ile bu girişin ağırlık değeri ile çarpımlarının eşik bir değer ile toplanmasıyla ifade edilir. Toplama fonksiyonu eşitlik (1.10)'da gösterilmiştir. Ayrıca toplama fonksiyonu ağ yapısına göre farklı fonksiyonlarla ifade edilebilir.

İlgili denklemlerde ifade edilen b değeri baz veya aktivasyon fonksiyonunun eşik değeri olarak ifade edilir.

$$\text{net} = \sum_{i=1}^n x_i w_i + b \quad (1.10)$$

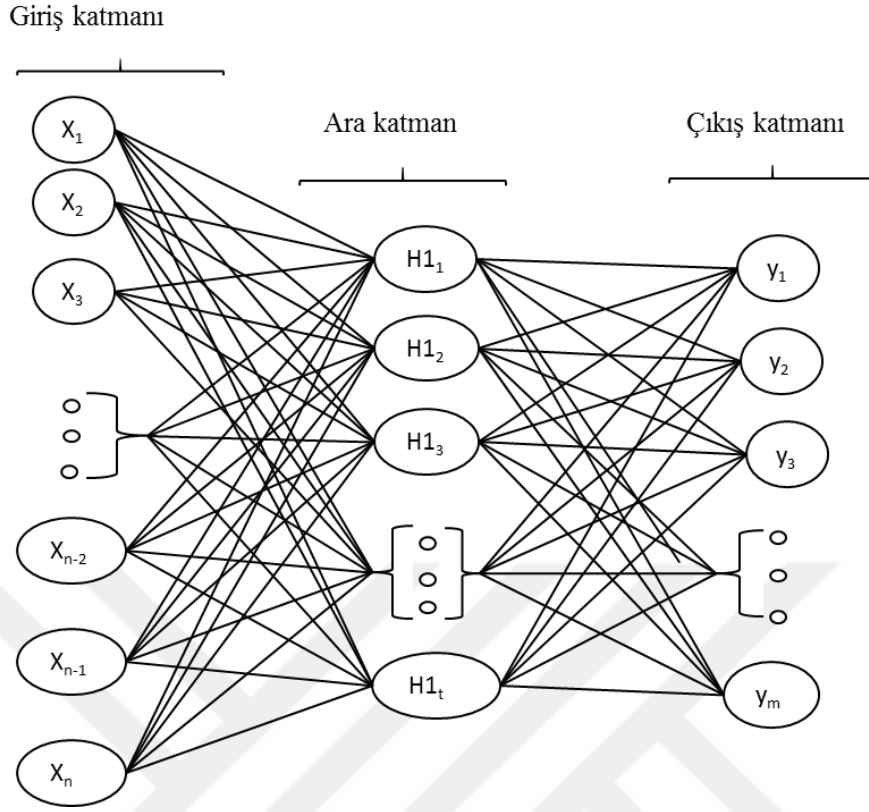
Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu, toplama fonksiyonundan elde edilen net deęerini iřlemden geirerek nron iin bir ıktı deęeri hesaplar. Aktivasyon fonksiyonu nronun ıkıřını belirli deęerler arasına sınırlandırır. Nron modellerinde doęrusal ve doęrusal olmayan aktivasyon fonksiyonları bulunmaktadır. zellikle lineer olmayan aktivasyon fonksiyonları karmařık problemlere yapay sinir aęlarının uygulanmasına olanak saęlamıřtır. ok katmanlı algılayıcı modellerinde en ok kullanılan aktivasyon fonksiyonu Sigmoid fonksiyonudur. Sigmoid fonksiyonu eřitlik (1.11)'de gsterilmiřtir.

$$f(net) = \frac{1}{1+e^{-net}} \quad (1.11)$$

Hcrenin ıktısı: Aktivasyon fonksiyonun rettięi deęerdir. ıktı deęeri, yapay sinir aęının ıktısı veya bařka hcrelerin girdisi olabilir.

1.6.3. ok Katmanlı Yapay Sinir Aęı Modeli

Yapay sinir aęları, yapay sinir hcrelerinin bir araya gelmesiyle oluřmuřtur. Katman sayısına gre tek katmanlı ve ok katmanlı YSA olarak incelenmektedir. Temel yapı olarak ok katmanlı yapay sinir aęları girdi katmanı, ara katman ve ıktı katmanından oluřmaktadır. ok katmanlı yapay sinir aęının genel yapısı Őekil 1.5'te gsterilmiřtir.



Şekil 1.5. Çok katmanlı yapay sinir ağı yapısı

Giriş katmanı, dış dünyadaki girdi değerlerinin yapay sinir ağına giriş yaptığı katmandır. Bu katmanda dış dünyadan gelecek giriş sayısı kadar hücre bulunur ve girdiler herhangi bir işleme uğramadan diğer katmanlara iletilir. Şekil 1.5'te X_n giriş verisindeki n , giriş katmanındaki nöron sayısını ifade etmektedir.

Ara katman, giriş katmanından alınan bilgilerin iletiildiği katmandır. Ara katmanın sayısı probleme göre değişiklik göstermektedir. Ara katman bulundurmeyen ağlar varken probleme göre birden fazla ara katman içeren yapay sinir ağları da vardır. Şekil 1.5'te $H1_t$ verisindeki t , ara katmandaki nöron sayısını ifade etmektedir.

Çıkış katmanı, ağın çıktı değerini üreten bu katman, ara katmanlardan gelen bilgileri işler. Üretilen çıktılar dış dünyaya gönderilir. Ancak ağ yapısı geri beslemeli ise, üretilen çıktı değeri yapay sinir ağında tekrar kullanılır. Şekil 1.5'te y_m verisindeki m , çıkış katmanındaki nöron sayısını ifade etmektedir.

1.6.4. Yapay Sinir Ağları Parametrelerinin Belirlenmesi

Zaman serisi ve neden-sonuç ilişkisine dayalı kestirim problemlerinde YSA'nın uygulanması için girdi nöronu sayısı, gizli katman ve gizli nöron sayısı ve çıktı nöronu sayısı, bunların yanı sıra eğitim algoritması, eğitim ve test kümelerinin belirlenmesi, veri normalleştirme yöntemi ve performans ölçütlerinin belirlenmesi gerekmektedir.

1.6.4.1. Katman Sayısının ve Nöron Sayılarının Belirlenmesi

Çok katmanlı yapay sinir ağı modellerinde giriş katmanında girdi nöronları ve gizli nöronlar bir veya daha fazla gizli katmanda, çıktı nöronları ise çıktı katmanında yer alır. Bu nöronların sayılarının belirlenmesi için bazı yöntemler önerilmiştir.

Girdi nöronu sayısı, neden-sonuç ilişkisine dayalı kestirim problemlerinde, girdi vektöründeki değişken sayısı kadardır. Zaman serisi kestirim problemlerinde girdi nöronu sayısı gecikme sayısı ile ilişkili olduğundan bu değer belirlenmesi için kesin bir yöntem yoktur.

Gizli katman ve gizli nöronlar veri içerisindeki belirleyici özellikleri ortaya çıkarması ve girdi ile çıktı arasındaki doğrusal olmayan ilişkinin kurulmasına yardımcı olması sebebiyle büyük bir öneme sahiptir. Birçok araştırmacı yaptıkları çalışmalarda tek gizli katman kullanımıyla doğrusal olmayan karmaşık fonksiyon yaklaşımlarında istenilen herhangi bir doğruluk derecesinde başarılı sonuçlar almaları sebebiyle geleceği kestirim için kurdukları ağda tek gizli katman kullanmayı tercih etmişlerdir.

Zhang ve arkadaşlarına göre, birçok kestirim problemi için tek gizli katman yeterlidir. Ancak, bazı özel problemlerde, iki gizli katmanlı ağ yapısı tek gizli katmanlı ağ yapısından daha iyi sonuç vermektedir [41].

Kaastra ve Boyd (1996) bütün YSA'ların öncelikle bir gizli katman ya da en fazla iki gizli katman kurularak çalıştırılmasını önermektedir. Eğer dört katmanlı bir ağ farklı gizli nöron sayısı ve rastgele başlangıç değerleri ile çalıştırıldığında iyi sonuç vermiyorsa, girdi değişkenlerinin gözden geçirilmesi ve yeniden düzenlenmesini önermiştir. Teori ve hemen hemen bütün deneysel çalışmalar ikiden fazla gizli katmanın ağın performansını iyileştirmediğini ifade etmektedir [42].

Bir ağıdaki gizli nöron sayısının belirlenmesi önemli bir karar olmasına rağmen bu sayının belirlenmesinde belirlenmiş herhangi bir formül bulunmamaktadır. Gizli nöron sayısının fazla tutulması ağın genelleme yapmasından çok ezberlemesine neden olmaktadır. Genelleme yeteneğinin fazla olması sebebiyle yapılan çalışmalarda genellikle az sayıda gizli nöron kullanımı tercih edilirken çok az sayıda gizli nöron kullanımı da ağın öğrenmesinde yeterli seviyeye ulaşamamasına sebep olmaktadır. Bu durumda kullanılacak gizli nöron sayısının deneysel çalışma sonucunda belirlenmesi gerekmektedir. Ağın performansı iyileşene kadar gizli nöron sayısının küçük bir değerle başlanıp giderek artırılmasıyla uygun nöron sayısı belirlenebilir [42].

Literatürde yapılan tek ara katmanlı bazı çalışmalarda gizli katman nöron sayısının belirlenmesi için bazı formüller önerilmiştir. Ancak bu formüller araştırmacılar tarafından kabul görmemiştir. Ayrıca Tang ve Fishwick (1993), gizli nöron sayısının kestirim performansında etkili olduğunu ancak bu etkinin çok da önemli olmadığını belirtmektedir [43].

Çıktı nöronu sayısı çalışılan probleme göre belirlenir. Kestirim probleminde çıktı nöronu sayısı, kestirim döneminin uzunluğuna eşittir. Tek dönemlik kestirimlerde 1'e, çok dönemlik kestirimlerde kestirim dönem sayısına eşittir.

1.6.4.2. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu bir nöronun veya ağın girdisi ve çıktısı arasındaki ilişkiyi belirlemektedir. Kestirim problemlerinde en yaygın kullanılan Sigmoid transfer fonksiyonudur. Ağın ürettiği çıktı değerleri kullanılan aktivasyon fonksiyonu ile hesaplanacağı için, ağ çıkışında kullanılacak hedef değerlerin bu fonksiyonla uyumlu bir aralıkta olması gerekmektedir.

1.6.4.3. Veri Normalleştirme

YSA modelinin girdi ve çıktılarının ölçeklendirilmesi ağın performansını etkilemektedir. Verilerin ölçeklendirilmesi veri setindeki değerlerin dağılımını düzenli hale getirmektedir. Girdilerin belirli aralıkta ölçeklendirilmesi hem farklı ortamlardan gelen bilgilerin aynı ölçek üzerine indirgenmesine hem de yanlış girilen çok büyük ve küçük

şekildeki değerlerin etkisinin ortadan kalkmasına neden olur. Hedef değerlerin ise ağ çıktısı ile aynı aralıkta olabilmesi için bu değerlerin aktivasyon fonksiyonuna göre ölçeklendirilmesi gerekmektedir [44]. Literatürde, Min-Max kuralı, Medyan, Sigmoid ve Z-Score gibi ölçeklendirme kuralları vardır [45]. Bu çalışmada Eşitlik (1.12)'de gösterilen D-minimum-maksimum ölçeklendirme yöntemi kullanılmıştır. X' , normalize edilmiş veri; X_i , girdi değeri; X_{min} , girdi seti içerisinde yer alan en küçük sayıyı ve X_{maks} , girdi seti içerisinde yer alan en büyük sayıyı ifade etmektedir.

$$X' = 0.8 * \frac{X_i - X_{min}}{X_{maks} - X_{min}} + 0.1 \quad (1.12)$$

1.6.4.4. Eğitim ve Test Kümesi

Bir YSA modelinin geliştirilmesi ve geliştirilen modelin kestirim yeteneğinin değerlendirilebilmesi için YSA kestiricisinin kurulumunda eğitim ve test örneklerine ihtiyaç vardır. Veri, eğitim ve test kümesi olmak üzere ikiye bölünür. Ancak bunu yapmanın belirli bir yöntemi yoktur. Problem özelliği, veri tipi ve eldeki veri miktarı bu kararı vermede dikkat edilen hususlardır. Hem eğitim kümesinin hem de test kümesinin bütününe özelliklerine sahip kümeler olması kritik bir noktadır. Bu nokta özellikle zaman serileri kestirim problemlerinde önemlidir. Eğitim ve test kümelerinin uygun olmayan bir şekilde belirlenmesi, optimal YSA yapısının seçimini ve YSA'nın kestirim performansının değerlendirilmesini etkileyecektir. Literatürde eğitim ve test kümelerinin belirlenmesinde kesin olarak belirlenmiş bir yaklaşım yoktur [41].

1.6.4.5. Tahminin Doğruluğunu Değerlendirme Ölçütleri

Bir YSA kestiricisi için en önemli performans ölçütü kestirimin doğruluğudur. Kestirimin doğruluğunun yanı sıra eğitim zamanı da performans ölçütü olarak kullanılmaktadır. Fakat, kestirim problemlerinde yaygın olarak kullanılan ve uygun bir doğruluk ölçütü belirlenmemiştir. Literatürde kestirim problemlerinde tahminin doğruluğunu analiz etmek için sıklıkla kullanılan performans ölçütleri, karesel ortalama hata (KOH), ortalama mutlak yüzde hata (OMYH), karesel ortalama hatanın karekökü (KOHK),

korelasyon katsayısı(r) ve ortalama mutlak hata (OMH)'dir. KOH eşitlik (1.13)'te, OMYH eşitlik (1.14)'te, korelasyon katsayısı(r) eşitlik (1.15)'te, KOHK eşitlik (1.16)'da ve OMH eşitlik (1.17)'de gösterilmiştir.

OMYH performans ölçütüne göre %10'un altında yapılan tahminler "yüksek doğruluk" derecesinde, %10-%20 arasında ise "doğru", %20-%50 arasında ise "kabul edilebilir" ve %50'nin üzerinde ise "yanlış ve hatalı" tahmin olarak nitelendirilir [46]. Korelasyon katsayısının (r) da 1'e yakın olması yüksek doğruluk ifade etmektedir. KOH, KOHK ve OMH gibi hata değerlerinin de küçük değerlerde olması istenmektedir.

$$KOH = \frac{1}{n} \sum_{i=1}^n (GI_{gerçek} - GI_{tahmin})^2 \quad (1.13)$$

$$OMYH = \frac{1}{n} \sum_{t=1}^n \left(\frac{|GI_{gerçek} - GI_{tahmin}|}{GI_{gerçek}} \right) * 100 \quad (1.14)$$

$$r = \frac{\sum(GI_{gerçek} - \bar{GI}_{gerçek})(GI_{tahmin} - \bar{GI}_{tahmin})}{\sqrt{\sum(GI_{gerçek} - \bar{GI}_{gerçek})^2 \sum(GI_{tahmin} - \bar{GI}_{tahmin})^2}} \quad (1.15)$$

$$KOHK = \sqrt{\frac{1}{n} \sum_{i=1}^n (GI_{gerçek} - GI_{tahmin})^2} \quad (1.16)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |GI_{gerçek} - GI_{tahmin}| \quad (1.17)$$

1.6.5. Yapay Sinir Ağlarında Öğrenme

YSA'nın öğrenmesi, belirli bir işlevi yerine getirmek için ağdaki ağırlık değerlerinin ayarlanması işlemidir. YSA'da bilginin saklandığı ağırlık değerleri başlangıçta rastgele atanır, örnekler ağa gösterilerek ağırlık değerleri değiştirilerek örnekler ağa öğretilir. Ağa sunulan örneklerin ağırlıklar ile test örnekleri için çıktılar üretir. Elde edilen çıktıların doğruluğu, ağın öğrenmesi hakkında bilgi verir.

Yapay sinir ağları ile bir probleme ait girdi verileri ile çıktı verileri arasındaki ilişkinin belirlenmesi için bu örneklerin ağa bir öğrenme algoritması ile öğretilmesi gerekmektedir. Ağın, bu ilişkiyi öğrenmesi ağdaki ağırlıkların en uygun değerlerde olmalarıyla mümkün

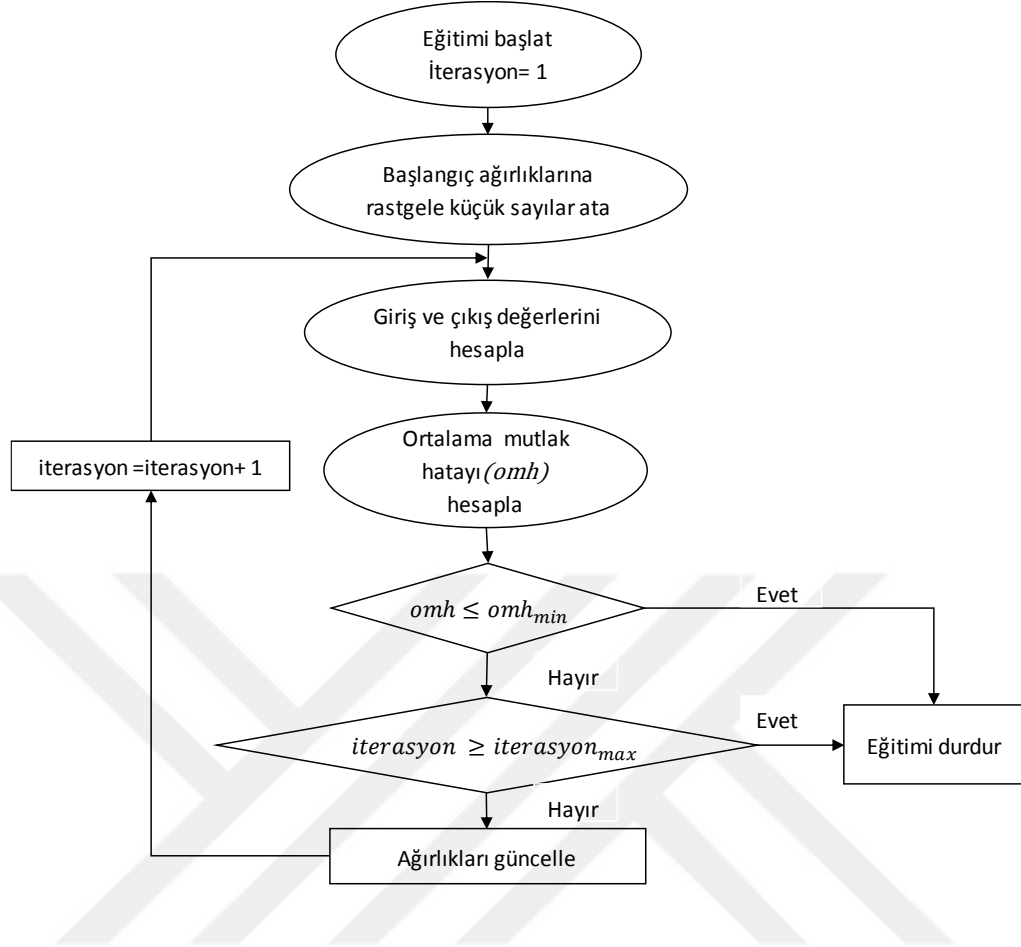
olmaktadır. W herhangi bir ağırlık değeri olmak üzere, eşitlik (1.18)'deki ΔW değişimini belirlemek için tanınmış kurallar öğrenme algoritmalarıdır.

Doğru çıktılar verebilmeleri yani ağıın genelleme yeteneğine ulaşmasıyla öğrenme gerçekleşir. Öğrenme, eğitim ve test olmak üzere iki aşamadan oluşmaktadır. Eğitim aşamasında eğitim örnekleri beklenen hedef değer ile ağa öğretilir. Ağ eğitildikten sonra, ağın öğrenip öğrenmediğini değerlendirmek için test aşamasına geçilir. Test aşamasında ağın görmediği örnekler ağa sunulur ve ağ, eğitim aşamasında sabitlenen ağırlıklarla test edilir.

$$W_{yeni} = W_{eski} + \Delta W \quad (1.18)$$

1.6.6. Yapay Sinir Ağlarının Eğitilmesi

Ağın eğitilmesi için gerekli olan ağırlıklar, başlangıçta rastgele olarak atanır. Rastgele olarak atanan ağırlıklar eğitime hangi noktadan başlanacağını belirlemektedir. Yapay sinir ağlarında önemli noktalardan biri eğitimin ne kadar sürdürüleceğine karar verilmesidir. Eğitime işleminin tamamlanması için iki seçenek mevcuttur. Bunlardan ilki belli bir miktardaki hata toleransı belirleyerek, o hata değerinden daha düşük hata değerine ulaşmaya kadar eğitmeyi sürdürmektir. Diğer seçenek ise sabit bir eğitim sayısının seçilmesidir. Burada eğitici, belirlenen eğitim sayısı sonucunda elde edilecek olan hatayı kabul etmektedir [47]. Ağın eğitim akış şeması Şekil 1.6'da gösterilmiştir.



Şekil 1.6. Eğitim akış şeması

1.6.6.1. Geri Yayılım Algoritması

Geri yayılım algoritması ile ağırlık eğitimi üç aşamadan oluşur. Bunlar girdi eğitim örüntüsünün ileri beslemesi, hesaplama ve hatanın geri yayılımı ve ağırlıkların güncellenmesidir.

x : Girdi eğitim vektörü,

$$x = (x_1, \dots, x_i, \dots, x_n),$$

t : Çıktı hedef vektörü,

$$t = (t_1, \dots, t_k, \dots, t_m),$$

δ_k : Çıktı ünitesi Y_k ' da bir hata nedeniyle w_{jk} ' nin ağırlık güncellemesi için hata düzeltme payı.

δ_j : Çıktı tabakasından gizli ünite Z_j ' ye hata bilgisinin geri yayılımı nedeniyle V_{ij} ' nin ağırlık güncellemesi için hata düzeltme payı.

α :Öğrenme oranı

X_t : Girdi ünitesi i ,

Bir girdi ünitesi için, girdi sinyali ve çıktı sinyali aynıdır (yani x_i).

v_{oj} : Gizli ünite j ' de eşik değeri

z_j : Gizli ünite j ,

z_j için net girdi z_in_j ile ifade edilirse z_in_j eşitlik (1.19)'daki şekilde hesaplanır;

$$z_in_j = v_{oj} + \sum_i x_i v_{ij} \quad (1.19)$$

Z_j ' nin çıktı sinyali z_j ile ifade edilirse z_j eşitlik (1.20)'deki şekilde hesaplanır;

$$z_j = f(z_in_j) \quad (1.20)$$

w_{ok} : Çıktı ünitesi k ' da eşik değeri

Y_k : Çıktı ünitesi k ,

Y_k ' nin çıktı sinyali y_k ile ifade edilirse y_k eşitlik (1.21)'deki şekilde hesaplanır;

$$y_k = f(y_in_k) \quad (1.21)$$

Eğitim sürecinde her çıktı ünitesi, o ünitenin örüntüsü ile ilişkili olan hatayı belirlemek için hesaplanan aktivasyonunu (y_k), hedef değeriyle (t_k) karşılaştırılır. Bu hataya dayanarak, δ_k ($k=1, \dots, m$) hesaplanır. δ_k çıkış ünitesi Y_k ' daki hatayı önceki katmandaki tüm ünitelere (Y_k ile bağlantılı tüm gizli üniteler) geri dağıtmak için kullanılır. Benzer şekilde faktör δ_j ($j=1, \dots, p$) her gizli ünite Z_j için hesaplanır. Hatayı giriş katmanına geri yaymak gerekli değildir ancak δ_j , gizli katman ile gizli katman arasındaki ağırlıkları güncellemek için kullanılır.

Tüm δ faktörler belirlendikten sonra, tüm katmanlar için olan ağırlıklar aynı anda güncellenir. Ağırlık w_{jk} (gizli ünite Z_j ' den çıkış ünitesi Y_k ' ya) için güncelleme, faktör δ_k ve gizli ünite Z_j ' nin çıktı ünitesi z_j aktivasyonuna dayandırılır. Ağırlık v_{jk} (giriş ünitesi X_i ' den gizli ünite Z_j ' ye) için güncelleme, faktör δ_i ve x_i giriş ünitesinin aktivasyonuna dayandırılır.

Geriye yayılım algoritması için bir aktivasyon fonksiyonu, birtakım önemli özelliklere sahip olmalıdır. Sürekli, türevi alınabilir bir fonksiyon tercih edilir. Sıklıkla kullanılan sigmoid aktivasyon fonksiyonu eşitlik (1.22)'de ve türevi de eşitlik (1.23)'te gösterilmiştir [48].

$$f(x) = 1/(1 + \exp(-x)) \quad (1.22)$$

$$f'(x) = f(x)[1 - f(x)] \quad (1.23)$$

Algoritma adımları:

Adım 0: Ağırlıkları başlat. (Küçük rastgele değer ata).

Adım 1: Durdurma işlemi hatalı olduğundan 2-9 adımlarını yap.

Adım 2: Her bir eğitim çifti için, 3-8 adımlarını yap.

İleri besleme:

Adım 3: Her giriş ünitesi ($x_i, i=1, \dots, n$), x_i giriş sinyalini alır ve bu sinyali gizli katmandaki tüm ünitelere iletir.

Adım 4: Her gizli ünite ($Z_j, j=1, \dots, p$) ağırlıklı giriş sinyallerini eşitlik (1.24)'teki şekilde toplar.

$$z_in_j = v_{jj} + \sum_{i=1}^n x_i v_{ij} \quad (1.24)$$

Çıkış sinyalini hesaplamak için, eşitlik (1.25)'teki şekilde kendi aktivasyon fonksiyonunu uygular ve bu sinyali çıkış ünitelerine gönderir.

$$z_j = f(z_in_j) \quad (1.25)$$

Adım 5: Her çıkış ünitesi ($Y_k, k=1, \dots, m$) kendi ağırlık giriş sinyallerini eşitlik (1.26)'da ki şekilde toplar.

$$y_in_k = w_{ok} + \sum_{j=1}^p z_j v_{jk} \quad (1.26)$$

Ve eşitlik (1.27)'deki şekilde kendi çıkış sinyallerini hesaplamak için kendi aktivasyon fonksiyonunu uygular.

$$y_k = f(y_{in_k}) \quad (1.27)$$

Hatanın geri yayılımı:

Adım 6: Her çıkış ünitesi (Y_k , $k=1, \dots, m$) giriş eğitim örüntüsüne karşılık gelen bir hedef örüntü alır, hata bilgi terimini eşitlik (1.28) ile hesaplar.

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (1.28)$$

Ağırlık düzeltme terimini eşitlik (1.29) ile hesaplar (Daha sonra w_{jk} güncellemek için kullan),

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (1.29)$$

Eşik değeri düzeltme terimini eşitlik (1.30) ile hesaplar (Daha sonra w_{ok} güncellemek için kullanılan)

$$w_{ok} = \alpha \delta_k \quad (1.30)$$

Ve δ_k 'yi aşağı katmandaki ünitelere gönderir.

Adım 7: Her gizli ünite (Z_j , $j=1, \dots, p$) kendi delta girişlerini (yukarı katmandaki ünitelerden) eşitlik (1.31)'deki şekilde toplar.

$$\delta_{in_j} = v_{jj} + \sum_{k=1}^m \delta_k w_{jk} \quad (1.31)$$

Kendi hata bilgi teminini hesaplayacak olan aktivasyon fonksiyonunun türevi ile eşitlik (1.32)'deki şekilde çarpar.

$$\delta_i = \delta_{in_j} f'(z_{in_j}) \quad (1.32)$$

Ağırlık düzeltme terimini eşitlik (1.33)'deki şekilde hesaplar.

$$\Delta w_{ij} = \alpha \delta_j x_i \quad (1.33)$$

Ve eşik değer düzeltme terimini eşitlik (1.34)'teki şekilde hesaplar.

$$\Delta w_{oj} = \alpha \delta_j \quad (1.34)$$

Ağırlıkları ve eşik değerleri güncelle:

Adım 8: Her çıkış ünitesi (Y_k , $k = 1, \dots, m$) eşik değer ağırlığını eşitlik (1.35)'teki şekilde günceller ($j = 0, \dots, p$):

$$w_{jk}(\text{yeni}) = w_{jk}(\text{eski}) + \Delta w_{jk} \quad (1.35)$$

Her gizli ünite (Z_j , $J=1, \dots, p$), eşik değer ve ağırlığını eşitlik (1.36)'daki şekilde günceller ($i = 0, \dots, n$)

$$v_{ij}(\text{yeni}) = v_{ij}(\text{eski}) + \Delta v_{ij} \quad (1.36)$$

Adım 9: Durdurma durumunu test et.

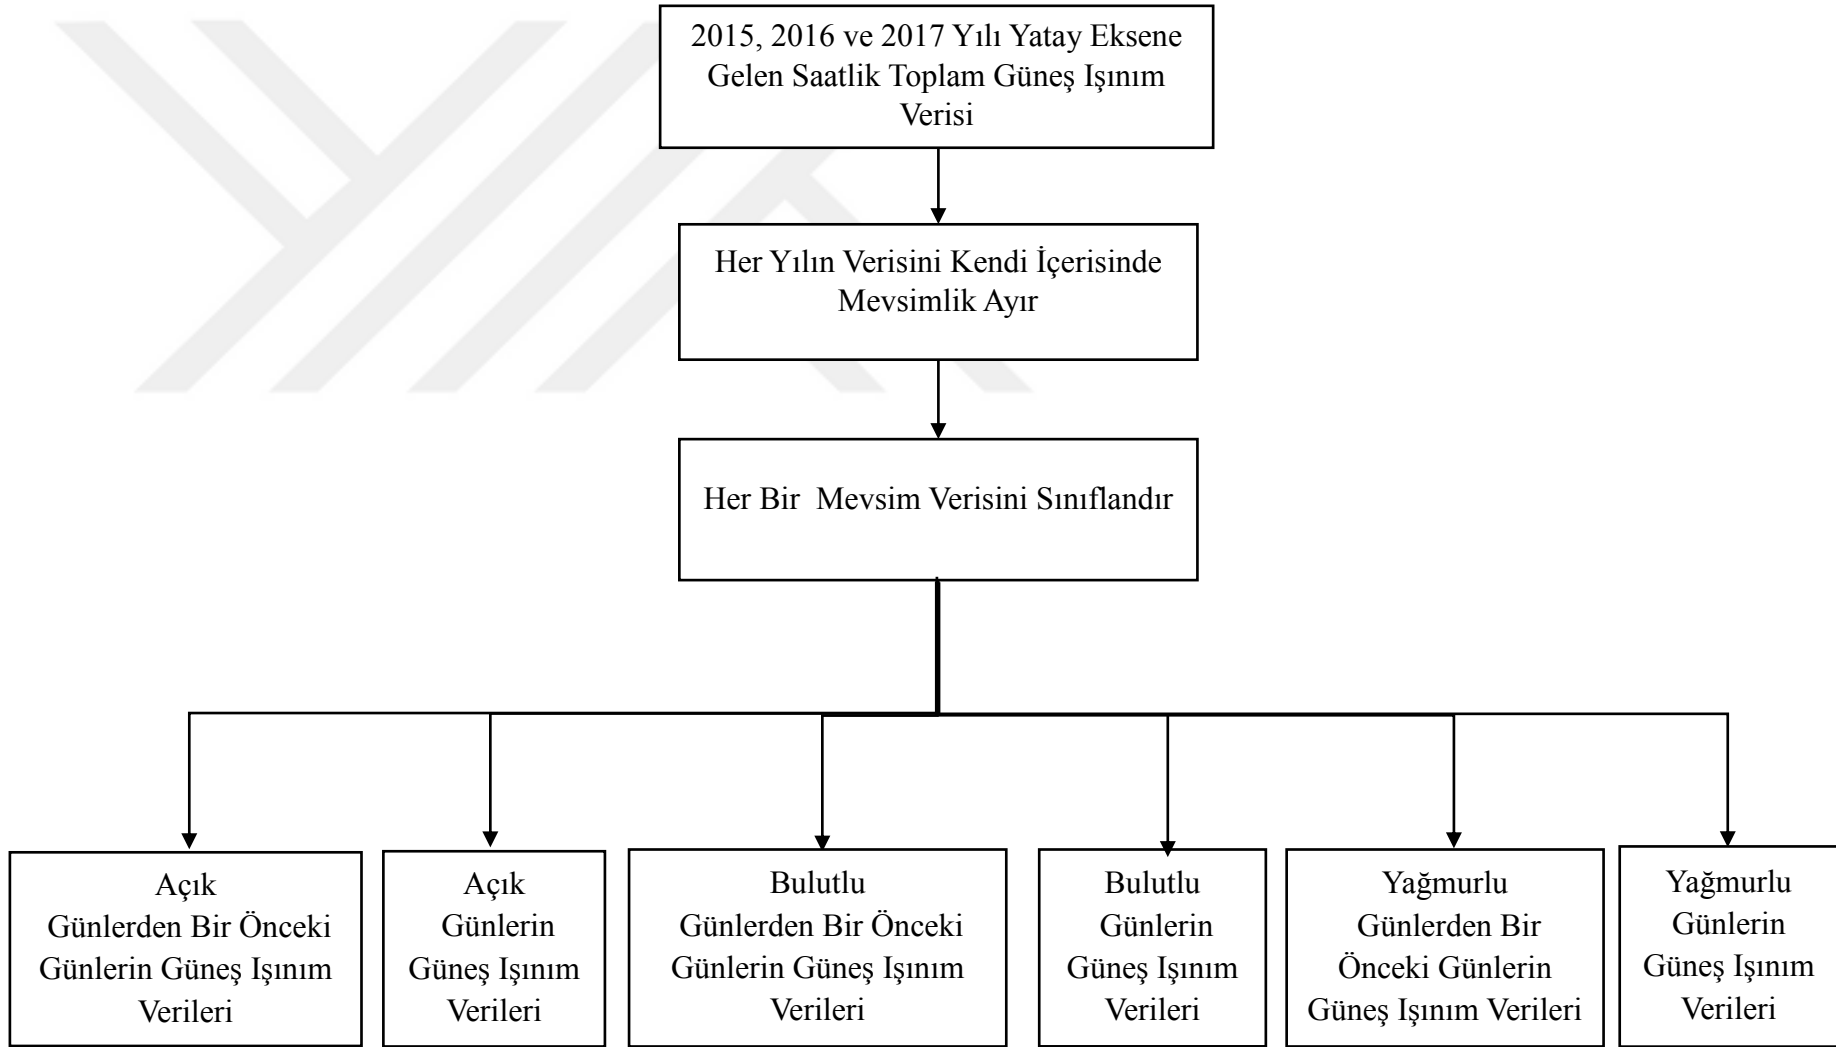
2. YAPILAN ÇALIŞMALAR, BULGULAR, İRDELEME

2.1. Giriş

Güvenilir ve ekonomik çalışma için FV güç sistemi çalışmaları, gerçek zamanlı, bir gün önceden, haftalık, aylık ve yıllık planlanır. Güvenilir ve kararlı bir elektrik şebekesi oluşturmak için FV sistemlerden yapılacak olan elektrik enerjisi üretim miktarının doğru tahmin edilmesini gerekmektedir. FV sistemlerle elektrik üretimi yapılan bir bölgenin güneş ışınımının tahmin edilmesiyle, FV sistemlerden üretilecek olan güç miktarı da kestirilebilir. Bu tez çalışması kapsamında, Trabzon ili için gün öncesi saatlik FV güç kestirimi yapılabilmesi için gün öncesi saatlik güneş ışınım kestirimi yapılması amaçlanmıştır. Bu çalışmada, problemin çözümü için verilerin kümelenme işlemi için k-medoids yöntemi ve ışınım tahmini için de yapay zeka yöntemlerinden çok katmanlı yapay sinir ağı yaklaşımı önerilmiştir. MATLAB’de programlanan yöntemlerle elde edilen sonuçların performansı değerlendirilmiştir.

2.2. Güneş Işınımı Kestirimi İçin Verilerin Düzenlemesi

Yatay eksene gelen saatlik toplam güneş ışınımı kestiriminde verilerin düzenlenmesi için gerekli adımlar örneği, Şekil 2.1’de gösterilmiştir. 2015, 2016 ve 2017 yatay eksene gelen saatlik toplam güneş ışınım verileri her bir yıl için mevsimlik olarak ayrılmıştır. Veriler her bir yıl için 4 adet, toplamda 12 alt kümeye ayrılmıştır. Daha sonra bu 12 alt küme, günlerin açıklık indeks değerlerine göre açık, bulutlu ve yağmurlu olmak üzere 3 kümeye ayrılarak her bir yılın, her bir mevsimindeki açık, bulutlu ve yağmurlu günlerin saatlik güneş ışınım verileri ve bu günlerden bir önceki günlerin saatlik güneş ışınım verileri belirlenmiştir.



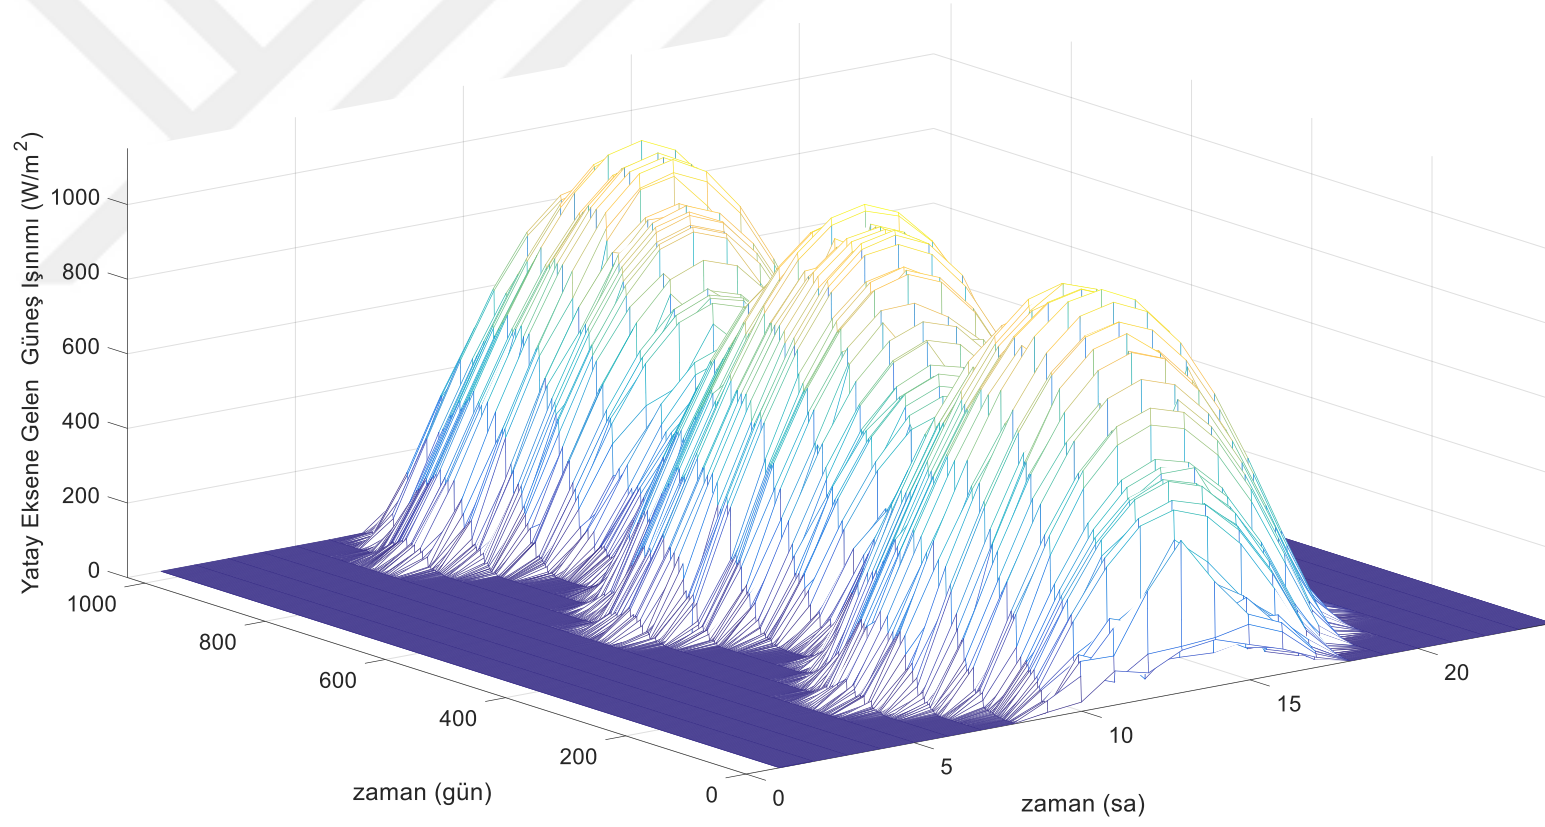
Şekil 2.1. Verilerin düzenlenmesi için gerekli adımlar

2.2.1. Trabzon İlinin Saatlik Güneş Işınım Verisi

Bu çalışmada, yatay düzleme gelen saatlik güneş ışınımı verisi Trabzon (enlem: 40.991150, boylam: 39.784964) ilinin 2015 ve 2016 yılları için bütün günler, 2017 yılı için 1 Ocaktan 25 Ekim gününe kadar [49] numaralı kaynaktan elde edilmiştir. 1 Ocak 2015'ten başlayarak 25 Ekim 2017 tarihine kadar yatay düzleme gelen saatlik ortalama güneş ışınımı verisi Şekil 2.2'de gösterilmiştir. Güneş ışınım verisi, 2015 yılı 1 Ocak saat 00:00 ile 25 Ekim 2017 saat 23:00 arasında, 2015 yılı için 8760, 2016 yılı için 8784 ve 2017 yılı için 7152 saat olmak üzere toplam 24696 saatlik güneş ışınım verisinden oluşmaktadır. Her bir yılın mevsimlere göre ölçülmüş yatay eksene gelen günlük ortalama güneş ışınım şiddeti değerleri Tablo 2.1'de verilmiştir.

Tablo 2.1. Trabzon ili için mevsimlere göre hesaplanan günlük ortalama güneş ışınım şiddeti


Yıl	Mevsim Bilgisi	Günlük Ortalama Güneş Işınım Şiddeti (kW/m ²)
2015	Kış	1.93
2015	İlkbahar	4.20
2015	Yaz	4.80
2015	Sonbahar	2.98
2016	Kış	1.66
2016	İlkbahar	6.69
2016	Yaz	7.51
2016	Sonbahar	4.93
2017	Kış	1.97
2017	İlkbahar	6.39
2017	Yaz	7.59
2017	Sonbahar	5.74



Şekil 2.2. Yatay düzleme gelen saatlik güneş ışınımı verisi

Tablo 2.1’de Trabzon ili için verilen günlük toplam ortalama güneş ışınım şiddeti, mevsimlere göre oldukça değişkendir. Yıllık olarak incelendiğinde, 2015 yılının günlük toplam ortalama güneş ışınım şiddeti 3.48 kW/m^2 iken bu değer 2016 yılında 5.20 kW/m^2 , 2017 yılında 5.42 kW/m^2 olarak hesaplanmıştır. Yıllık ve mevsimden mevsime oldukça farklılık gösteren güneş ışınımı verisi saatlik olarak da bulut verisine bağlı olarak değişkenlik göstermektedir.

Güneş Işınım verinin saatlik olarak daha net görülebilmesi amacıyla Şekil 2.3’te 1 Ocak ile 5 Ocak 2015 tarihleri arasındaki 5 günlük veri gösterilmiştir.

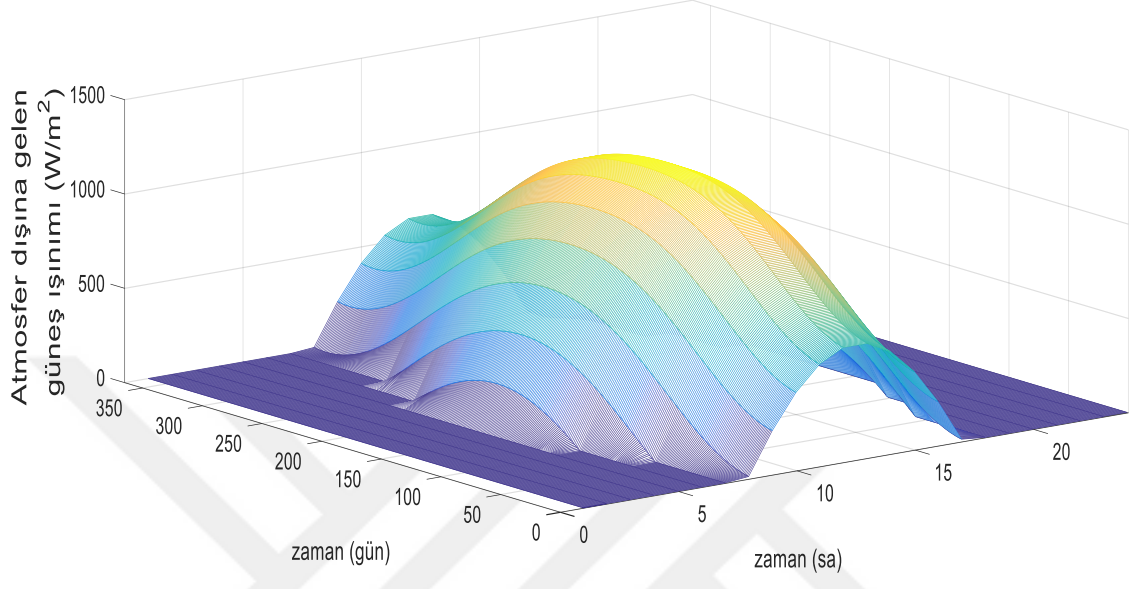


Şekil 2.3. 1-5 Ocak 2015 tarihleri arasında yatay düzleme gelen saatlik güneş ışınımı

2.2.2. Saatlik Açıklık İndeks Hesabı


Saatlik açıklık indeks hesabı, yatay düzleme bir saatlik periyotta gelen toplam güneş ışınımının aynı saatler arasında atmosfer dışına gelen toplam güneş ışınımına oranı ile hesaplanmaktadır. Bu indeks değerinin hesaplanabilmesi için atmosfer dışına gelen saatlik güneş ışınım verisinin bilinmesi gereklidir. Trabzon ili için atmosfer dışına gelen saatlik güneş ışınım verisi eşitlik (1.5) ile hesaplanmıştır.

Bir yıl boyunca, Trabzon iline atmosfer dışından gelen saatlik güneş ışınımı Şekil 2.4'te gösterilmiştir. Bu veri, $365 \times 24 = 8760$ saatlik güneş ışınım verisinden oluşmaktadır.



Şekil 2.4. Atmosfer dışına gelen saatlik güneş ışınımı verisi

Atmosfer dışına gelen güneş ışınım verisini hesaplandıktan sonra ölçülmüş yatay düzleme gelen saatlik güneş ışınımı verisi ile her bir saat için açıklık indeksi hesabı eşitlik (1.7) ile yapılmıştır. 1 Ocak 2015 ile 5 Ocak 2015 tarihleri için atmosfer dışına gelen saatlik güneş ışınımı verisi Şekil 2.5'te gösterilmiştir.




Şekil 2.5. 1-5 Ocak 2015 tarihleri arasında atmosfer dışına gelen saatlik güneş ışınımı

2.2.3. Günlük Açıklık İndeks Hesabı

Her bir günün açıklık indeksini hesaplamak için günlerin saat 9.00 ile 17.00 arasındaki saatlik açıklık indeks verileri kullanılmıştır. Eşitlik 2.1’de gösterildiği gibi her bir gün için 9 saatlik açıklık indeks verisinin ortalaması alınarak günlük açıklık indeksi belirlenmiştir.

$$K_{\text{gün}} = (K_9 + K_{10} + K_{11} + K_{12} + K_{13} + K_{14} + K_{15} + K_{16} + K_{17}) / 9 \quad (2.1)$$

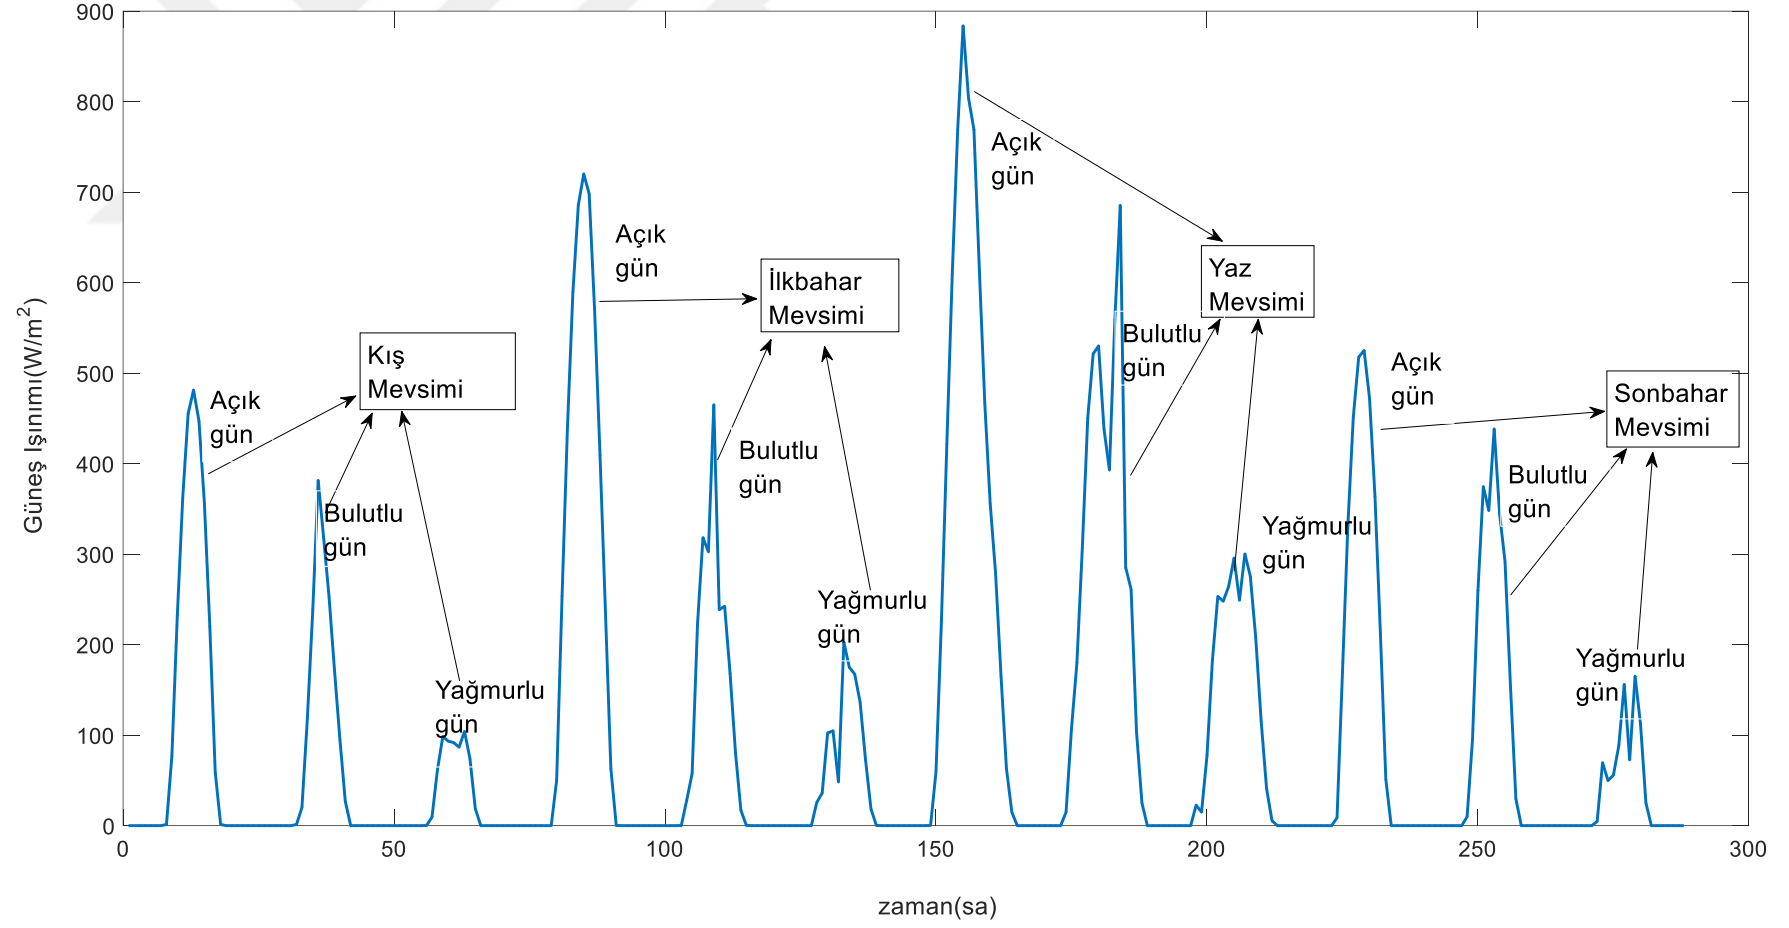
2015, 2016 ve 2017 yılı 25 Ekim gününe kadar 1028 gün için hesaplanan günlük açıklık indeks verileri Şekil 2.6’da gösterilmiştir.



Şekil 2.6. Günlük açıklık indeks verileri

2.3. Verilerin Kümelmesi

Günlük açıklık indeksi günlerin kümelmesi için kullanılacak parametredir. Kümeleme çalışmasının yapılma amacı günleri açık, bulutlu ve yağmurlu olmak üzere üç kümeye ayırmaktır. Rastgele belirlenmiş her mevsimden açık, bulutlu ve yağmurlu günlerin saatlik güneş ışınımı verileri Şekil 2.7’de gösterilmiştir.



Şekil 2.7. Örnek açık, bulutlu ve yağmurlu günlerin güneş ışınım verileri

Açık günlerin saatlik güneş ışınımı verisi dağılımı normal dağılım karakteristiği göstermektedir. Açık günlerde bulut verisi olmadığından, saatlik veri dağılımında dalgalanmalar oluşmamaktadır. Bulutlu günlerin saatlik güneş ışınımı veri dağılımı bulut verisinden kaynaklanan dalgalanmalar içermektedir. Yağmurlu günlerin güneş ışınımı dağılımı ise bulut verisinin oldukça yoğun olması sebebiyle diğer günlere göre daha küçük genlikte güneş ışınım verisine ulaşabilmektedir. Şekil 2.6'da açıkça görüldüğü üzere, her bir gün tipinin ulaşabildiği güneş ışınım şiddeti değerleri mevsimden mevsime, saatten saate farklılık göstermektedir.

2.3.1. Verilerin Mevsimlere Göre Düzenlenmesi

Her bir yılın güneş ışınım verisi ile günlük açıklık indeks değerleri ayrı ayrı mevsimlik alt kümelere ayrılmıştır. Verilerin düzenlenmesinde kullanılan aylar ve mevsimleri Tablo 2.2'de gösterilmiştir.

Tablo 2.2. Aylar ve Mevsimleri

Aylar	Mevsim
Aralık-Ocak-Şubat	Kış
Mart-Nisan-Mayıs	İlkbahar
Haziran-Temmuz-Ağustos	Yaz
Eylül-Ekim-Kasım	Sonbahar

2015, 2016 ve 2017 yılı 25 Ekim gününe kadar her bir günün güneş ışınım verisi ile günlük açıklık indeks değerleri düzenlenerek 12 alt kümeye bölünmüştür.

2.3.2. K-Medoids Algoritması ile Verilerinin Kümelenmesi

Günlük açıklık indeks değerleri ile 12 alt kümenin her biri kendi içerisinde kümeleme işlemine tabi tutulmuştur. Her bir alt küme, açık, bulutlu ve yağmurlu olmak üzere k-medoids algoritması kullanılarak 3 kümeye ayrılmıştır. Kümeleme işlemi yapıldıktan sonra her bir kümeye ait güneş ışınım verisi belirlenirken, ilgili günden bir önceki günün güneş ışınım verisi de saklanmıştır. Bir önceki günün güneş ışınım verisi yapay sinir ağlarının girişleri olarak, ilgili günün saatlik güneş ışınım verisi ise hedef değerler olarak


kullanılacaktır. Yapılan kümeleme işlemine örnek göstermek amacıyla, 2015 yılı kış mevsimi için yapılan kümeleme işlemi ile belirlenen açık, bulutlu ve yağmurlu günlere ait saatlik güneş ışınım verileri Şekil 2.8’de gösterilmiştir.

Kümeleme analizinin sonuçlarının kalitesini değerlendirmek için küme geçerliliği tekniklerinden Silhouette indeksi kullanılmıştır. Tablo 2.3’te kümeleme işlemi ile belirlenmiş açık, bulutlu ve yağmurlu günlerin sayıları ile her bir alt küme için hesaplanmış Silhouette indeks değeri verilmiştir.

Tablo 2.3. Kümeleme işlemleri ile belirlenmiş günler, sayıları ve Silhouette indeks değerleri

Yıl	Mevsim Bilgisi	Açık Gün Sayısı	Bulutlu Gün Sayısı	Yağmurlu Gün Sayısı	Silhouette İndeksi
2015	Kış	27	25	37	0.66
2015	İlkbahar	26	28	37	0.62
2015	Yaz	22	33	39	0.60
2015	Sonbahar	38	19	33	0.65
2016	Kış	19	24	46	0.63
2016	İlkbahar	27	28	34	0.62
2016	Yaz	27	33	31	0.64
2016	Sonbahar	21	30	39	0.61
2017	Kış	23	16	19	0.67
2017	İlkbahar	26	23	42	0.60
2017	Yaz	37	17	37	0.66
2017	Sonbahar	24	12	18	0.65

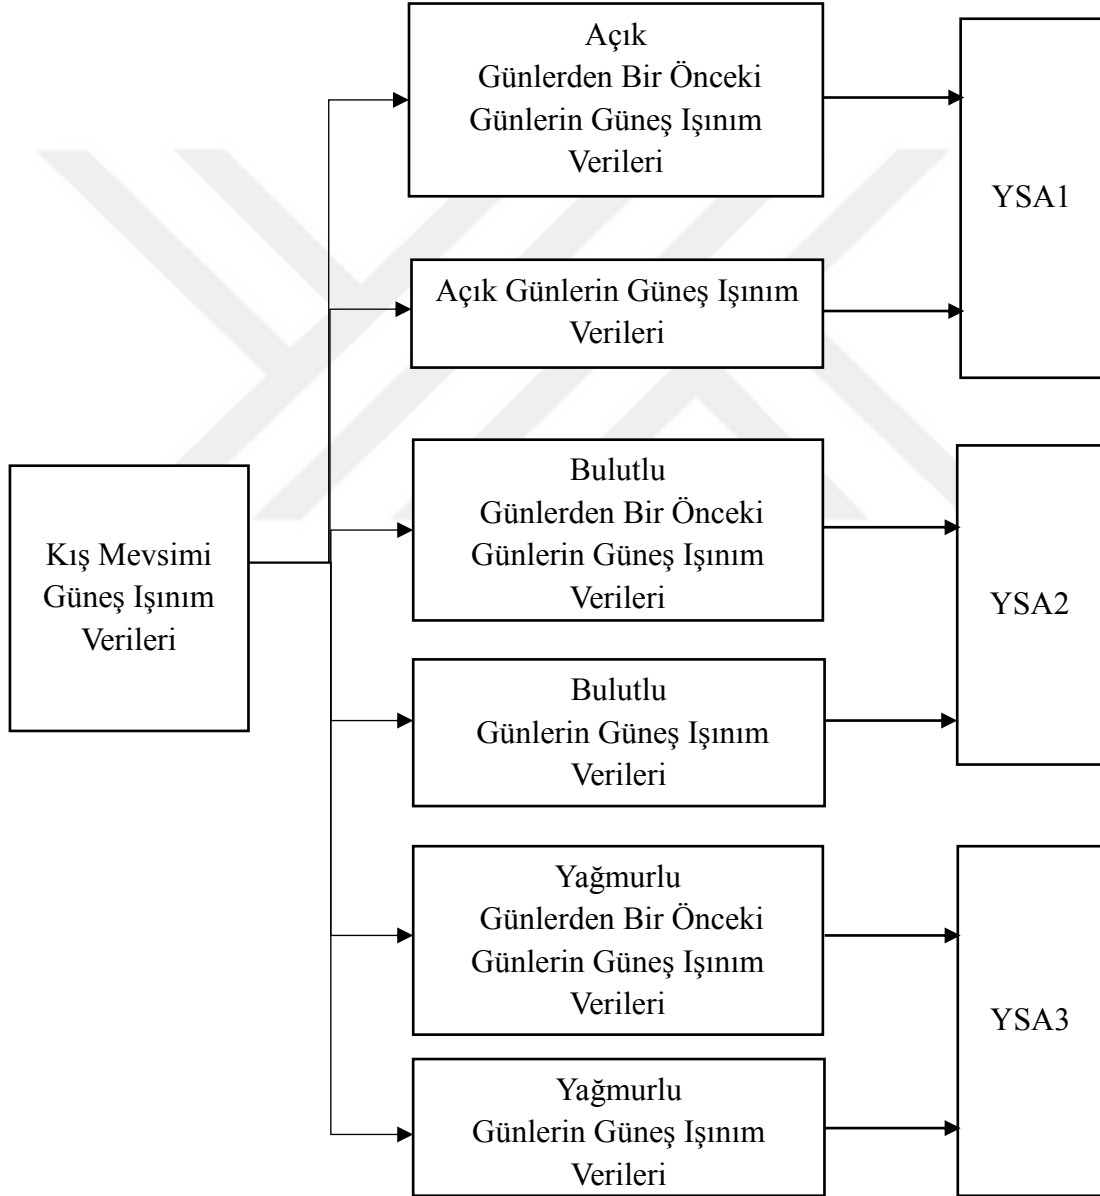
Silhouette endeksleri bütün kümeler için ortalama 0.6’dan büyük çıkmıştır. [50] numaralı kaynağa göre bu sonuç kümeleme işlemi için başarılı bir sonuçtur.



Şekil 2.8. 2015 yılı kış mevsimi için yapılan kümelenmiş örnek veriler

2.4. Gün Öncesi Saatlik Güneş Işınımı Verisinin Tahmin Edilmesi İçin Tasarlanan Sistemin Genel Yapısı

Problemin çözümü için tasarlanan sistemin genel yapısı kış mevsimi örneği ile Şekil 2.9'da gösterilmiştir. Veri düzenleme işlemi tamamlandıktan sonra her bir mevsimdeki açık, bulutlu ve yağmurlu günler için ayrı ayrı YSA'lar tasarlanmıştır. Toplamda 12 farklı YSA tasarlanmıştır.



Şekil 2.9. Sistemin genel yapısı (örnek: kış mevsimi)


Kış mevsimi hedefi açık günler olan örnekler için YSA1, hedefi bulutlu günler olan örnekler için YSA2, hedefi yağmurlu günler olan örnekler için YSA3 tasarlanmıştır. İlkbahar mevsimi hedefi açık günler olan örnekler için YSA4, hedefi bulutlu günler olan örnekler için YSA5, hedefi yağmurlu günler olan örnekler için YSA6 tasarlanmıştır. Yaz mevsimi hedefi açık günler olan örnekler için YSA7, hedefi bulutlu günler olan örnekler için YSA8, hedefi yağmurlu günler olan örnekler için YSA9 tasarlanmıştır. Sonbahar mevsimi hedefi açık günler olan örnekler için YSA10, hedefi bulutlu günler olan örnekler için YSA11, hedefi yağmurlu günler olan örnekler için YSA12 tasarlanmıştır. Her bir YSA için giriş ve çıkış verileri Tablo 2.4'te verilmiştir.

Tablo 2.4. YSA'lar için giriş ve çıkış verileri

YSA Modeli	Giriş verileri	Çıkış verileri
YSA1, YSA4, YSA7, YSA10	Açık günlerden bir önceki günün saatlik güneş ışınım verisi	Açık günlerin saatlik güneş ışınım verisi
YSA2, YSA5, YSA8, YSA11	Bulutlu günlerden bir önceki günün saatlik güneş ışınım verisi	Bulutlu günlerin saatlik güneş ışınım verisi
YSA3, YSA6, YSA9, YSA12	Yağmurlu günlerden bir önceki günün saatlik güneş ışınım verisi	Yağmurlu günlerin saatlik güneş ışınım verisi

Her bir ağ 2015 ve 2016 yıllarının günlerinin saatlik güneş ışınımı verileri ile eğitilip 2017 yılının günlerinin saatlik güneş ışınımı verileri ile test edilmiştir. Her bir ağ için eğitilen ve test edilen örnek sayısı kümeleme işlemine bağlı olarak değişiklik göstermektedir. Her bir ağ için eğitim ve test kümesi örnek sayıları her bir mevsim için ayrılmış alt başlıklarda gösterilmiştir.

Problemin çözümü için tasarlanan iki ara katmanlı YSA modeli Şekil 2.10'da gösterilmiştir. Ağın çıkışları olan y_1 - y_{24} elemanları, 24 saatlik hedef günün güneş ışınım şiddeti verileri ve ağın girişleri olan x_1 - x_{24} elemanları ise hedef günden bir önceki günün 24 saatlik güneş ışınım şiddeti verileridir. H_{1t} ile gösterilen birinci ara katman nöron sayısı 24, H_{2t} ile gösterilen ikinci ara katman nöron sayısı 20 olarak belirlenmiştir. Ağlar geri yayılım algoritması ile eğitilmiştir. Hedefi açık olan günler için ağlar 5000, hedefi bulutlu ve yağmurlu olan günler için 10000 iterasyon çalıştırılmıştır.



Şekil 2.10. Tasarlanan yapay sinir ağı modeli

2.5. Önerilen Yöntemin Uygulanması ve Sonuçlar

2.5.1. Kış Mevsimi Ağları

Kış mevsimi için Tablo 2.4'te gösterilen giriş ve çıkış değerlerine ve Tablo 2.5'te belirtilen eğitim ve test örnek sayılarına göre ağlar eğitilip test edilmiştir.

Tablo 2.5. Kış mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları


YSA Yıl	Eğitilen Örnek Sayısı		Test edilen Örnek Sayısı
	2015	2016	2017
YSA1	27	19	23
YSA2	25	24	16
YSA3	37	46	19

Hedefi açık günler olan günler için Şekil 2.11’de, hedefi bulutlu olan günler için Şekil 2.12’de ve hedefi yağmurlu olan günler için de Şekil 2.13’te gerçek ve kestirilmiş saatlik güneş ışınım değerleri gösterilmiştir. Ayrıca ağlar için hesaplanan eğitim ve test hatası değerleri Tablo 2.6’da verilmiştir.


Tablo 2.6. Kış Mevsimi YSA’ları eğitim ve test seti hataları

YSA	Eğitim		Test			
	KOH (W/m ²)	r	OMYH (%)	KOHK (W/m ²)	OMH (W/m ²)	r
YSA1	0.001	0.98	4.10	27.95	13.84	0.99
YSA2	0.003	0.94	7.46	47.98	23.60	0.95
YSA3	0.002	0.92	7.35	34.79	17.51	0.95


Elde edilen test hatalarına bakıldığında OMYH performans ölçütüne göre YSA1 ile %4.10, YSA2 ile %7.46 ve YSA3 ile %7.35 ile kestirim yapılmıştır. OMYH performans ölçütüne göre YSA1, YSA2 ve YSA3 ile yüksek doğruluk derecesinde kestirim yapılmıştır.



Şekil 2.11. Kış mevsimi açık günler (YSA1) test kümesinin gerçek ve kestirilmiş güneş ışıınımlı değeri



Şekil 2.12. Kış mevsimi bulutlu günler (YSA2) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri



Şekil 2.13. Kış mevsimi yağmurlu günler (YSA3) test kümesinin gerçek ve kestirilmiş güneş ışıınımmı değerleri

2.5.2. İlkbahar Mevsimi Ağları

İlkbahar mevsimi için Tablo 2.4'te gösterilen giriş ve çıkış değerlerine ve Tablo 2.7'de belirtilen eğitim ve test örnek sayılarına göre ağlar eğitilip test edilmiştir.

Tablo 2.7. İlkbahar mevsimi YSA'ları için Eğitim ve test kümesi örnek sayıları


YSA	Eğitilen Örnek Sayısı		Test edilen Örnek Sayısı
	2015	2016	2017
YSA4	26	27	26
YSA5	28	28	23
YSA6	37	34	42

Hedefi açık günler olan günler için Şekil 2.14'te, hedefi bulutlu olan günler için Şekil 2.15'te ve hedefi yağmurlu olan günler için de Şekil 2.16'da gerçek ve kestirilmiş saatlik güneş ışınım şiddeti değerleri gösterilmiştir. Ayrıca ağlar için hesaplanan eğitim ve test hatası değerleri Tablo 2.8'de verilmiştir.


Tablo 2.8. İlkbahar mevsimi YSA'ları eğitim ve test seti hataları

YSA	Eğitim		Test			
	KOH (W/m ²)	r	OMYH (%)	KOHK (W/m ²)	OMH (W/m ²)	r
YSA4	0.001	0.99	5.66	47.20	26.98	0.98
YSA5	0.004	0.94	11.9	107.1	59.85	0.93
YSA6	0.003	0.92	11.3	97.25	48.86	0.87


Elde edilen test hatalarına bakıldığında OMYH performans ölçütüne göre YSA4 ile %5.66, YSA5 ile %11.9 ve YSA6 ile %11.3 ile kestirim yapılmıştır. OMYH performans ölçütüne göre YSA4 ile yüksek doğruluk derecesinde, YSA5 ve YSA6 ile doğru kestirim yapılmıştır.



Şekil 2.14. İlkbahar mevsimi açık günler (YSA4) test kümesinin gerçek ve kestirilmiş güneş ışıınımmı değerleri



Şekil 2.15. İlkbahar mevsimi bulutlu günler (YSA5) test kümesinin gerçek ve kestirilmiş güneş ışıınımlı deęerleri



Şekil 2.16. İlkbahar mevsimi yağmurlu günler (YSA6) test kümesinin gerçek ve kestirilmiş güneş ışıınımlı değerleri

2.5.3. Yaz Mevsimi Ağları

Yaz mevsimi için Tablo 2.4'te gösterilen giriş ve çıkış değerlerine ve Tablo 2.9'da belirtilen eğitim ve test örnek sayılarına göre ağlar eğitilip test edilmiştir.

Tablo 2.9. Yaz mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları


YSA	Eğitilen Örnek Sayısı		Test edilen Örnek Sayısı
	2015	2016	2017
YSA7	22	27	37
YSA8	33	33	17
YSA9	29	31	37

Hedefi açık günler olan günler için Şekil 2.17'de, hedefi bulutlu olan günler için Şekil 2.18'de ve hedefi yağmurlu olan günler için de Şekil 2.19'da gerçek ve kestirilmiş saatlik güneş ışınım şiddeti değerleri gösterilmiştir. Ayrıca ağlar için hesaplanan eğitim ve test hatası değerleri Tablo 2.10'da verilmiştir.


Tablo 2.10. Yaz Mevsimi YSA'ları Eğitim ve test seti hataları

YSA	Eğitim		Test			
	KOH (W/m ²)	r	OMYH (%)	KOHK (W/m ²)	OMH (W/m ²)	r
YSA7	0.001	0.98	5.79	59.35	29.13	0.98
YSA8	0.006	0.92	12.15	102.9	59.67	0.93
YSA9	0.004	0.89	14.17	99.00	55.33	0.87


Elde edilen test hatalarına bakıldığında OMYH performans ölçütüne göre YSA7 ile %5.79, YSA8 ile %12.15 ve YSA9 ile %14.17 ile kestirim yapılmıştır. OMYH performans ölçütüne göre YSA7 ile yüksek doğruluk derecesinde, YSA8 ve YSA9 ile doğru kestirim yapılmıştır.



Şekil 2.17. Yaz mevsimi açık günler (YSA7) test kümesinin gerçek ve kestirilmiş güneş ışıınımlı değerleri



Şekil 2.18. Yaz mevsimi bulutlu günler (YSA8) test kümesinin gerçek ve kestirilmiş güneş ışıınımlı değeri



Şekil 2.19. Yaz mevsimi yağmurlu günler (YSA9) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri

2.5.4. Sonbahar Mevsimi Ağları

Sonbahar mevsimi için Tablo 2.4'te gösterilen giriş ve çıkış değerlerine ve Tablo 2.11'de belirtilen eğitim ve test örnek sayılarına göre ağlar eğitilip test edilmiştir.

Tablo 2.11. Sonbahar mevsimi YSA'ları için eğitim ve test kümesi örnek sayıları


YSA	Eğitilen Örnek Sayısı		Test edilen Örnek Sayısı
	2015	2016	2017
YSA10	38	21	24
YSA11	19	30	12
YSA12	33	39	18

Hedefi açık günler olan günler için Şekil 2.20'de, hedefi bulutlu olan günler için Şekil 2.21'de ve hedefi yağmurlu olan günler için de Şekil 2.22'de gerçek ve kestirilmiş saatlik güneş ışınım şiddeti değerleri gösterilmiştir. Ayrıca ağlar için hesaplanan eğitim ve test hatası değerleri Tablo 2.12'da verilmiştir.


Tablo 2.12. Sonbahar Mevsimi YSA'ları Eğitim ve test seti hataları

YSA	Eğitim		Test			
	KOH (W/m ²)	r	OMYH (%)	KOHK (W/m ²)	OMH (W/m ²)	r
YSA10	0.002	0.97	4.33	38.05	20.57	0.99
YSA11	0.002	0.97	9.29	79.58	38.14	0.92
YSA12	0.002	0.90	9.84	77.64	33.98	0.83


Elde edilen test hatalarına bakıldığında OMYH performans ölçütüne göre YSA10 ile %4.33, YSA11 ile %9.29 ve YSA12 ile %9.84 ile kestirim yapılmıştır. OMYH performans ölçütüne göre YSA10, YSA11 ve YSA12 ile yüksek doğruluk derecesinde kestirim yapılmıştır.



Şekil 2.20. Sonbahar mevsimi açık günler (YSA10) test kümesinin gerçek ve kestirilmiş güneş ışınımı değerleri



Şekil 2.21. Sonbahar mevsimi bulutlu günler (YSA11) test kümesinin gerçek ve kestirilmiş güneş ışıınımmı değerleri



Şekil 2.22. Sonbahar mevsimi yağmurlu günler (YSA12) test kümesinin gerçek ve kestirilmiş güneş ışınlımlı değerleri

2.6. Önerilen Yöntemin Diğer Çalışmalarla Karşılaştırılması

Literatürde yapılan çalışmalarda her araştırmacı çalışmasını yaptığı bölge için, güneş ışınımı verisi ve bazı meteorolojik tahmin verileri de kullanarak saatlik güneş ışınımı kestirimi yapmışlardır. Saatlik güneş ışınımı verisi bölgeden bölgeye iklimsel özelliklere bağlı olarak değiştiğinden ve yapılan çalışmalarda her araştırmacının farklı sayıda eğitim ve test verisi kullanmaları sebebiyle direkt bir karşılaştırma işlemi yapılamamaktadır.

Ancak bu çalışmaya benzer olarak bazı araştırmacılar gün tipine bağlı (açık, bulutlu ve yağmurlu) örnekler ile önerdikleri sistemleri test etmişlerdir. Literatürde bütün çalışmalar en iyi kestirimlerini açık günler ile yapmıştır. Ancak yapılan çoğu çalışmada, mevsimden mevsime, aydan aya, günden güne ve saatten saate oldukça değişiklik gösteren güneş ışınım verisinin test işlemi oldukça az örnekle yapılmıştır. Bu tez çalışmasında önerilen sistemde, neredeyse bir yıllık veri test işlemi için kullanılmış ve özellikle açık günler için farklı mevsimlerde dahi oldukça başarılı sonuçlar elde edilmiştir.

3. SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında, FV güç sistemi çalışmalarının kararlı bir şekilde çalışmasını sağlamak ve akıllı şebekede yapılacak olan yük planlama çalışmalarına katkı sağlamak amacıyla gün öncesi saatlik güneş ışınım kestirimi yapılmıştır. Trabzon iline ait geçmiş yılların saatlik güneş ışınımı verisi kullanılarak gün öncesinden ertesi günün saatlik güneş ışınım verisi yapay zeka yöntemlerinden yapay sinir ağları(YSA) yaklaşımı ile kestirilmiştir. Güneş ışınım verisi analiz edilip mevsimsel olarak ayrıştırılarak k-medoids algoritması ile kümeleme işlemine tabi tutulmuştur. Kümeleme işlemi sonucunda günler hava tipine göre açık, bulutlu ve yağmurlu olmak üzere üç farklı sınıfa ayrılmıştır. Kümeleme işlemi ile farklı sınıflardaki günlerin güneş ışınım değerleri belirlenirken bu günlerden bir önceki günlerin saatlik güneş ışınım verileri de saklanmıştır. Her bir sınıf için farklı bir yapay sinir ağı tasarlanmıştır. Her bir sınıfa ait güneş ışınım verileri YSA'ların hedef değerleri olarak, bu günlerden bir önceki günlerin güneş ışınım verileri ise YSA'ların giriş değerleri olarak kullanılmıştır. Tasarlanan YSA modeli, MATLAB benzetim programında MATLAB'nin YSA araç kutusunda bulunan kodlar kullanılmadan tasarlanmıştır. Ağların eğitimleri 2015 ve 2016 yıllarına ait saatlik güneş ışınımı verileri ile yapılırken test işlemi 2017 yılına ait saatlik güneş ışınım verileri ile yapılmıştır. Yapılan kestirimlerin doğruluğu çeşitli performans ölçütleri ile değerlendirilmiştir.

Literatürdeki çoğu çalışmada güneş ışınımı ile ilişkili olduğu düşünülen sıcaklık, nem gibi parametreler kullanılarak saatlik güneş ışınım kestirim çalışmaları yapılmıştır. Bazı araştırmacılar kestirim gününe ait gerçek ölçülmüş sıcaklık ve nem verilerini kullanarak, bazı araştırmacılar da kestirim gününe ait nem ve sıcaklık gibi verilerin gün öncesinden meteorolojik tahmin verilerini, ulusal hava tahmini veren kuruluşlardan elde ederek kullanmışlardır. Bu iki yöntemin de uygulanmasında problem oluşacaktır. Çünkü kestirim gününe ait nem ve sıcaklık verisi gün öncesinden saatlik olarak %100 doğru tahmin edilmesi mümkün değildir. Ve gün öncesinden tahmini saatlik nem ve sıcaklık değerleri bilinse bile, saatlik güneş ışınımı verisi ilgili saatin gerçek nem ve sıcaklık değeri ile ilişkilidir. Bu sebeplerden dolayı bu çalışmada güneş ışınımıyla alakalı meteorolojik bir veri kullanılmadan sadece geçmiş yıllarda yaşanan günlerin tekrarlamış olma ihtimali değerlendirilerek saatlik güneş ışınım kestirimi çalışması yapılmıştır.

Her bir mevsimdeki bütün ađlarda, ađların öğrenme hatalarına bakıldığında en iyi öğrenme açık günlerde, en az öğrenme işlemi de kapalı günler için yapılmıştır. Bulut verisinin saatlik olarak deđişiminin bilinmemesi bulutlu ve yağmurlu yüksek doğrulukta tahmin edilebilmesini kısıtlamaktadır. En başarılı ađlar, açık günler için yapılan ađlardır. En başarısız ađlar ise genellikle yağmurlu günler için yapılan ađlardır. Yağmurlu günlerde bulutlanmanın etkisini azaldığı günler için güneş ışınım verisinin ani maksimum noktasına geçişlerinin kestirimi yapılan kestirim çalışmasının en başarısız kısımlarıdır. Yağmurlu ve bulutlu günlerin saatlik güneş ışınım kestiriminin daha iyi yapılabilmesi için bulut verisinin gün öncesinden çok yüksek doğrulukta bilinmesi gerekmektedir.

Bu tez çalışması sırasında iki adet bildiri yayınlanmıştır[51,52].



4. ÖNERİLER

Uygulama yapılırken gün öncesinden ertesi günün hava tahmininin açık ve bol güneş ışığı olduğu günler için açık günler için tasarlanmış ağlar, yoğun bulutlu ve yağmurlu günler için yağmurlu günler için tasarlanmış ağlar, diğer durumlar için de bulutlu günler için tasarlanmış ağlar kullanılmalıdır.

Bu çalışmada saatlik güneş ışınım verisi incelenmiş, mevsimlere ve günlerin açıklık indeksi değerleri hesaplanarak 3 farklı gün tipine ayrılmıştır. Kümeleme algoritması olarak k-medoid algoritması kullanılarak veriler kümelenecek ve her bir küme için küme geçerlik indeksi ortalama olarak 0.6 olarak hesaplanmıştır. Kümeleme işleminin daha başarılı olabileceği gün tipleri üçten fazla küme için yapılabilir. Böylece güneş ışınım verisi de kendisine daha benzeyen kümede yer alarak çalışmada iyileşme sağlayabilir. Ayrıca bu çalışmada kestirim için YSA yaklaşımı kullanılmıştır. Gün öncesi çalışmalardan ziyade gün içi saatlik güneş ışınım kestirimi yapılan çalışmalarda sıklıkla destek vektör regresyonu yöntemi kullanılmaktadır. Bu yöntem gün öncesi çalışmalarda da kullanılabilir.

5. KAYNAKLAR

1. International Energy Outlook 2016, U.S. Energy Information Administration, 2016.
2. IEA-PVPS Trend Reports, International Energy Agency Photovoltaic Power System Programme, 2016.
3. Farhangi, H., The Path of the Smart Grid, IEEE Power and Energy Magazine, 8, 1 (2010) 18-28.
4. Logenthiran, T., Srinivasan, D. ve Shun, T. Z., Demand Side Management in Smart Grid Using Heuristic Optimization, IEEE Transactions on Smart Grid, 3, 3 (2012) 1244-1252.
5. Cakmak, R. ve Altas, I. H., Scheduling of Domestic Shiftable Loads Via Cuckoo Search Optimization Algorithm, 2016 4th International Istanbul Smart Grid Congress and Fair (ICSG), (2016) 1-4.
6. Wan, C., Song, J. Y., Xu, Z., Lin, J. ve Hu, Z., Photovoltaic and Solar Power Forecasting for Smart Grid Energy Management, Csee Journal of Power and Energy Systems, 1,4 (2015).
7. Reikard, G., Predicting Solar Radiation at High Resolutions: A Comparison of Time Series Forecasts, Solar Energy, 83,3 (2009) 342–349.
8. Lorenz, E., Hurka, J., Heinemann, D. ve Beyer, H. G., 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 (2009) 2–10.
9. Liu, J., Fang, W., Zhang X. ve Yang, C., An Improved Photovoltaic Power Forecasting Model With the Assistance of Aerosol Index Data , IEEE Transactions on Sustainable Energy, 6,2 (2015).
10. Ji, W. ve Chee, K. C., Prediction of Hourly Solar Radiation Using a Novel Hybrid Model of ARMA and TDNN, Solar Energy, 85,5 (2011) 808–817.
11. Benmouiza, K. ve Cheknane, A., Small-Scale Solar Radiation Forecasting Using ARMA and Nonlinear Autoregressive Neural Network Models, Theoretical and Applied Climatology, (2015) 1–14.

12. Voyant, C., Notton, G., Kalogirou, S., Nivet, M., N., Paoli, N., Motte, F., Fouilloy, A., Machine Learning Methods for Solar Radiation Forecasting: A Review, In Renewable Energy, 105 (2017) 569-582.
13. Mellit, A. ve Pavan, A. M., A 24-h Forecast of Solar Irradiance Using Neural Network: Application for Performance Prediction of a Grid-Connected PV Plant at Trieste, Solar Energy, 84,5 (2010) 807–821.
14. Ding, M., Wang, L. ve Bi, R., An ANN-based Approach for Forecasting the Power Output of Photovoltaic System, Procedia Environmental Sciences, 11 (2011) 1308-1315.
15. Grimaccia, F., Mussetta, M. ve Zich, R. E., Advanced Predictive Models Towards PV Energy Integration in Smart Grid, WCCI 2012 IEEE World Congress on Computational Intelligence, June 2012 - Brisbane, Australia, 10-15.
16. Ferrari, S., Lazzaroni, M., Piuri, V., Salman, A., Cristaldi, L. ve Faifer, M., Computational Intelligence Models for Solar Radiation Prediction, IEEE International Instrumental and Measurement Technology Conference, May 2013.
17. Yang, X., Jiang, F. ve Liu, H., Short Term Solar Radiation Prediction based on SVM with Similar Data , Renewable Power Generation Conference (RPG 2013), Sept. 2013, 2nd IET.
18. Baharin, K. A., Rahman, H. A., Hassan, M. Y. ve Gan, C. K. , Hourly Irradiance Forecasting in Malaysia Using Support Vector Machine, IEEE Conference, Oct. 2014, Johor Bahru, Malaysia.
19. Yan, X., Abbas, D. ve Francois, B., Solar Radiation Forecasting Using Artificial Neural Network for Local Power Reserve, 2014 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM), 2014, Tunis, 1-6.
20. Gandelli, A., Grimaccia, F., Leva, S., Mussetta, M., ve Ogliari, E., Hybrid Model Analysis and Validation for PV Energy Production Forecasting , 2014 International Joint Conference on Neural Networks (IJCNN), July, 2014, Beijing, China, 6-11.
21. Abuella , M. ve Chowdhury, B., Solar Power Forecasting Using Artificial Neural Networks, North American Power Symposium (NAPS), Oct. 2015, 4-6.
22. Watetakarn , S. ve Premrudeepreechacharn, S., Forecasting of Solar Irradiance for Solar Power Plants by Artificial Neural Network, Smart Grid Technologies - Asia (ISGT ASIA), Nov. 2015.
23. Li, Z., Zang, C., Yu, P. H. ve Li, H., Day-ahead Hourly Photovoltaic Generation Forecasting using Extreme Learning Machine , The 5th Annual IEEE International Conference on Cyber Technology in Automation, June 2015, Shenyang, China, 8-12.
24. Ceylan, O., Starke, M., Irminger, P., Ollis, B. ve Tomsovic, K., A Regression Based Hourly Day Ahead Solar Irradiance Forecasting Model By Labview Using Cloud Cover Data, 9th International Conference on Electrical and Electronics Engineering (ELECO), 2015, Bursa, 406-410.

25. Huang, C. M., Chen, S. J. ve Yang, S. P., One-Day-Ahead Hourly Forecasting For Photovoltaic Power Generation Using An Intelligent Method With Weather-Based Forecasting Models, IET Generation, Transmission & Distribution, 9,14 (2015) 1874-1882.
26. Moustiris, K. P., Kavvadias, K. A., Kokkosis, A. I. ve Paliatsos, A. G., One Day-Ahead Forecasting Of Mean Hourly Global Solar Irradiation For Energy Management Systems Purposes Using Artificial Neural Network Modeling, Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion (MedPower 2016), 2016, Belgrade, 1-6.
27. Rana, M., Koprinska, I. ve Agelidis, V. G., Solar Power Forecasting Using Weather Type Clustering And Ensembles Of Neural Networks, 2016 International Joint Conference on Neural Networks (IJCNN), 2016, Vancouver, 4962-4969.
28. Kallioğlu, M. A., Ercan, U., Avcı, A. S., Karakaya, H. ve Durmuş, A., Adiyaman İlinde Yatay düzleme Gelen Global Güneş Işınım Değerlerinin Ampirik Modeller ile Geliştirilmesi, Fırat Üniv. Müh. Bil. Dergisi, 29,1 (2017) 151-159.
29. Öztürk, M., Özek, N. ve Berkama, B., Aylık Ortalama Günlük Global Güneş Radyasyonu Tahmininde Mevcut Olan Bazı Modellerin Karşılaştırılması, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 18,1 (2012) 13-27.
30. Bulut, H., Büyükcalaca, O. ve Yılmaz, T., Akdeniz Bölgesinde Yatay Düzleme Gelen Günlük Toplam Güneş Işınımının Modellenmesi, Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 21,1-2 (2006) 33-44.
31. Bakırcı, K., Yatay Yüzeğe Gelen Anlık Global Güneş Işınımının Tahmini İçin Basit Bir Hesaplama Metodu, Isı Bilimi ve Tekniği Dergisi, 29,2 (2009) 53-58.
32. Akarslan, E. ve Hocaoğlu, F. O., A Novel Adaptive Approach For Hourly Solar Radiation Forecasting, Renewable Energy, 87,1 (2016) 628-633.
33. Hocaoğlu, F. O. ve Serttaş, F., A Novel Hybrid (Mycielski-Markov) Model for Hourly Solar Radiation Forecasting, Renewable Energy, 108 (2017) 635-643.
34. Tırıs, M., Tırıs, Ç. ve Erdalli, Y., Güneş Enerjili Su Isıtma Sistemleri, Tübitak-Marmara Araştırma Merkezi Enerji Sistemler ve Çevre Araştırma Enstitüsü, Kocaeli, 1997.
35. Öztürk, H., H., Güneş Enerjisi Ve Uygulamaları, Birsen Yayınevi, İstanbul, 2008.
36. Duffie J.A. ve Beckman W.A., Solar Engineering of Thermal Processes, Fourth Edition, John Wiley & Sons, New York, 2006.
37. Iqbal, M., An Introduction to Solar Radiation, Academic Press, Toronto, 1983.
38. Han, J., Pei, J. ve Kamber, M., Data Mining: Concepts and Techniques, Third Edition, The Morgan Kaufmann Series in Data Management Systems Morgan Kaufmann Publishers, 2011.
39. Rousseeuw, R., P., Silhouettes: A Graphical Aid To The Interpretation And Validation Of Cluster Analysis, Journal Of Computational And Applied Mathematics, 20 (1987) 53-65.

40. Martinez W., L. ve Martinez A., R., *Exploratory Data Analysis With Matlab (Computer Science And Data Analysis)*, Chapman & Hall/Crc, 2004.
41. Zhang, G., Patuwo, B.E. ve Hu, M.Y., *Forecasting With Artificial Neural Networks:The State Of The Art*, International Journal of Forecasting, 14 (1998) 35-62.
42. Kaastra, I. ve Boyd, M., *Designing A Neural Network For Forecasting Financial And Econometric Time Series*, Neurocomputing, 10 (1996) 215-236
43. Tang, Z. ve Fishwick, P.A., *Feedforward Neural Nets As Models For Time Series Forecasting*, ORSA Journal on Computing, 54 (1993) 374-385.
44. Yavuz, S. ve Deveci M., *İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi*, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 40 (2012) 167-187.
45. Jayalakshmi, T. ve Santhakumaran A., *Statistical Normalization and Back Propagation for Classification*, International Journal of Computer Theory and Engineering, 3,1 (2011) 793-8201.
46. Lewis, C., D., *Industrial and Business Forecast Methods*, Butterworths Publishing, London, 1982.
47. Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul, 2003.
48. Zurada J., M., *Introduction to Artificial Neural Systems*, West Publishing Co., 1992.
49. <http://www.soda-pro.com/web-services/radiation/cams-radiation-service>. 27 Ekim 2017.
50. Benmouiza, K. ve Cheknane, A., *Forecasting hourly global solar radiation using hybrid k-means and nonlinear autoregressive neural network models*, In Energy Conversion and Management, 75 (2013) 561-569.
51. Çevik, S., Çakmak, R. ve Altaş, İ. H., *A day ahead hourly solar radiation forecasting by artificial neural networks: A case study for Trabzon province*, *International Artificial Intelligence and Data Processing Symposium (IDAP)*, 2017, Malatya, 1-6.
52. Çevik, S., Çakmak, R. ve Altaş, İ. H., *Meteorolojik Tahmin Destekli Yapay Sinir Ağı ile Gün Öncesi Saatlik Güneş Işınımı Kestirimi: Trabzon ili Örneği*, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı (ASYU)*, 2017, Alanya.

ÖZGEÇMİŞ

Sibel ÇEVİK, 1992 yılında Trabzon'un Düzköy ilçesinde doğdu. İlköğretim ve ortaöğretimini Akçaabat'ta tamamlamış olup, 2010 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünden mezun oldu. Aynı sene Karadeniz Teknik Üniversitesi'nde yüksek lisans eğitimine başladı. 11.04.2017-11.10.2017 tarihleri arasında TÜBİTAK 115E943 nolu projede bursiyer öğrenci olarak çalışmıştır.

