



T.C.

**BATMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GÜNEŞ IŞINIM TAHMİNİ İÇİN FARKLI TAHMİN
YÖNTEMLERİNİN KARŞILAŞTIRILMASI: GÜNEYDOĞU
ANADOLU BÖLGESİ ÖRNEĞİ**

YAHYA AKIL

YÜKSEK LİSANS

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ A.B.D

**Eylül-2019
BATMAN**

TEZ BİLDİRİMİ

TEZ KABUL VE ONAYI

Yahya Akıl tarafından hazırlanan "Güneş Işınım Tahmini İçin Farklı Tahmin Yöntemlerinin Karşılaştırılması: Güneydoğu Anadolu Bölgesi Örneği" adlı tez çalışması 30/09/2019 tarihinde aşağıdaki jüri üyeleri tarafından oy birliği ile Batman Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

DECLARATION PAGE

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Cafer BUDAK

Danışman

Dr. Öğr. Üyesi Musa YILMAZ

Üye

Doç. Dr. Ömer Faruk ERTUĞRUL

(Handwritten signatures of the jury members)

Yukarıdaki sonucu onaylarım.

Prof. Dr. Şahinaz TİĞREK
FBE Müdürü



TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Öğrencinin Adı SOYADI

Tarih:

ÖZET

YÜKSEK LİSANS

GÜNEŞ IŞINIM TAHMİNİ İÇİN FARKLI TAHMİN YÖNTEMLERİNİN KARŞILAŞTIRILMASI: GÜNEYDOĞU ANADOLU BÖLGESİ ÖRNEĞİ

Yahya AKIL

**Batman Üniversitesi Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğretim Üyesi Musa YILMAZ

2019, 74 Sayfa

Jüri

Dr. Öğretim Üyesi Musa YILMAZ

Doç. Dr. Ömer Faruk ERTUĞRUL

Dr. Öğretim Üyesi Cafer BUDAK

Fosil yakıtların azalması ve çevre kirliliğinin artışından dolayı ülkemizde potansiyeli yüksek olan güneş enerjisi çok önemli hale gelmiştir. İhtiyaç duyulan enerji arzının güneş enerjisinden elde edilmesi için kurulacak güneş santrallerinin fizibilite çalışmaları yapılmalıdır. Bu çalışmalar için güneş ışıınımı miktarının tespit edilmesi ve uygun bölgelerin seçilmesi gerekmektedir. Işınım profili için gerekli girdilerin ölçülmesi ve elde edilen girdiler vasıtasıyla ışıınım profilinin uygun yöntemler ile tahmininin yapılması gereklidir. Böylece kurulacak tesisin veriminin belirlenmesi sağlanmış olacaktır. Bundan dolayı, bu çalışma, yatırımcılar açısından, yatırım yapılacak alanın uygunluğunu belirlemeye imkân tanıyacaktır.

Bu çalışma kapsamında; Güneydoğu Anadolu Bölgesinde bulunan beş İl'de (Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin) güneş ışıınım profili tahmini için on farklı yöntem incelenmiştir. Her bir il için Temel Bileşen Analizi (TBA) uygulayarak ve TBA uygulanmaksızın sonuçlar elde edilmiştir. Bu sonuçlar analiz edilerek uygun yöntemler belirlenmiştir. TBA uygulandığında sonuçlarda belirgin iyileşme saptanmıştır. Lineer regresyon yöntemi TBA uygulanmaksızın sonuçlar incelendiğinde; tüm iller için en uygun yöntem olduğu görülmektedir. TBA uygulayarak elde edilen sonuçlar açısından ise, beş il içinde Lineer destek vektör makinesi en uygun yöntem olarak tespit edilmiştir. TBA özellik çıkarımı sağlayarak; verimliliği artırmakla kalmamış aynı zaman da hangi parametrelerin doğru tahmin yapmada önemli olduğunu da göstermiştir. TBA uygulanarak güneş ışıınım süresinin %83 ile doğru tahminde bulunması açısından en önemli parametre olduğu görülmüştür.

Anahtar Kelimeler: Solar Enerji, Global güneş ışıınımı, Makine öğrenmesi, Regresyon, TBA (Temel bileşen analizi).

ABSTRACT

MS THESIS

COMPARİSON OF FORECASTİNG METHODS FOR ESTIMATION OF SOLAR IRRADIATION: THE CASE OF SOUTHEAST ANATOLİA REGION

Yahya AKIL

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRİCAL AND ELECTRONİCS ENGINEERING**

Advisor: Dr. Öğretim Üyesi Musa YILMAZ

2019, 74 Pages

Jury

Dr. Öğretim Üyesi Musa YILMAZ

Doç. Dr. Ömer Faruk ERTUĞRUL

Dr. Öğretim Üyesi Cafer BUDAK

Due to the reduction of fossil fuels and the increase of environmental pollution; solar energy, which has a considerable potential in our country, has become vital. In order to obtain the required energy supply from solar energy, feasibility studies of solar power plants to be established should be carried out. For these studies, the amount of solar irradiation should be identified and the appropriate regions should be chosen. It is crucial to measure the inputs required for the irradiation profile and to be able to estimate the irradiation profile through the appropriate methods. Hence, the efficiency of the facility to be established could be identified. Therefore, this study will allow the investors to determine the appropriateness of the area to be invested.

This study comprises ten different methods that were employed to estimate the solar irradiation profile in the five provinces of Southeast part of Anatolia; Diyarbakır, Şanlıurfa, Gaziantep, Batman and Mardin. The results obtained by applying Principal Component Analysis (PCA) and without applying PCA for each province. By elaborating these results, appropriate methods were identified. The results presented significant improvement when PCA was applied. When Lineer regression method is employed without applying PCA, It is observed that it is the most proper method for all the provinces. In terms of the results obtained by applying PCA, Lineer support vector machine for five provinces were determined as the most proper methods. By providing PCA feature extraction; productivity was increased and it was attained which parameters were important in estimating, simultaneously. By applying PCA, it was found that solar irradiation time was the most important parameter for estimation methods with 83%.

Keywords: Solar Energy, Global solar irradiation, Machine learning, Regression, PCA (Principal component analysis).

ÖNSÖZ

Tez çalışmasının tüm aşamalarında desteklerini esirgemeyen çok değerli iki bilim insanı; danışman hocam Dr. öğretim üyesi Musa YILMAZ ve Öğretim Görevlisi Heybet KILIÇ'a, yüksek lisans süresince desteklerini esirgemeyen bölüm başkanımız Doç. Dr. Ömer Faruk ERTUĞRUL'a ve sınıf arkadaşım, değerli dostum Dr. Öğretim Üyesi Muhammed Sait AYDIN 'a, Evlendiğim günden bu yana her türlü çabamın ortağı ve destekçisi olan değerli eşim Fatime'ye ve yine tez çalışması süresince mutluluk kaynaklarım biricik kızım Amine Büşra ve oğlum Ali İmran'a gönülden teşekkür ediyorum.

Yahya AKIL
BATMAN-2019

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
TABLO VE ŞEKİLLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1 Güneş Işınımı	1
1.2 Güneş Sabitesi	2
1.3 Güneş Açısı	3
1.3.1 Zenit Açısı.....	3
1.3.2 Güneş Yüksekliği Açısı	3
1.3.3 Azimut Açısı tanımı	4
1.3.4 Yüzey Azimut Açısının Tanımı	4
1.3.5 Güneş Yön Açısı.....	4
1.4 Radyasyon Ölçümü	5
1.4.1 Pirometre	5
1.4.1.1 Anemometre (Yel Ölçer)	6
1.4.1.2 Ortam Sıcaklık Ölçer	7
1.4.1.3 Güneşlenme Zamanı Sensörü	7
1.4.1.4 Bağıl Nem Algılayıcı(Sensör)	8
1.4.2 Meteorolojik Uydular	8
1.4.2.1 Meteorolojik Uydu Kullanım Alanları ve Amaçları.....	9
1.4.2.2 Uydu Tipleri.....	9
1.4.2.2.1 Sabit Yörüngeli Uydular	9
1.4.2.2.2 Kutupsal Yörüngeli Uydular.....	10
1.4.2.2.3 III. Nesil Uydu Programı	10
1.5 Yenilenebilir Enerji.....	11
1.5.1 Fotovoltaik Güneş Enerjisi	11
1.5.2 Hidroelektrik (Enerji) Santralleri	11
1.5.3 Rüzgâr Türbin enerjisi	12
1.5.4 Jeotermal Isı Enerjisi	13
1.6 Yenilenebilir Enerjiye Küresel Bakış.....	13
1.7 Yenilenebilir Enerji ve Türkiye’deki Gelişim Süreci	16
1.8 Güneydoğu Anadolu Bölgesi’ndeki Beş İl için Güneş Enerjisi Potansiyeli	20

2	KAYNAK ARAŞTIRMASI	31
2.1	Ampirik Yöntem Kaynak Araştırması	31
2.2	Makine Öğrenmesi Kaynak Araştırması.....	32
2.3	Bulanık Mantık ve Genetik Algoritma Kaynak Araştırması	33
3	MATERYAL VE YÖNTEM.....	35
3.1	Ampirik Yöntemler ve Hesaplama.....	35
3.2	Makine Öğrenmesi ve Kullanılan Yöntemler	36
3.2.1	Yapay Sinir Ağları	37
3.2.2	Destek Vektör Regresyonu (SVR).....	39
3.2.3	Huber Regrasyonu	40
3.2.4	Ridge ve LASSO Regrasyon	40
3.2.5	Bayesian Ridge Regresyonu	41
3.2.6	Bagging Regresyonu.....	42
3.2.7	Random Forest Regresyonu.....	42
3.2.8	AdaBoost Regresyonu	43
3.2.9	Lineer Regresyon (LR)	43
3.3	Temel Bileşen Analizi (TBA)	44
3.4	Hata Doğrulamasının istatistiksel değerlendirilmesi	46
4	ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	48
4.1	Farklı İller için TBA uygulayarak ve TBA uygulanmaksızın Elde Edilen Sonuçlar	49
5	SONUÇLAR VE ÖNERİLER	55
	KAYNAKLAR	57
	ÖZGEÇMİŞ	63

TABLO VE ŞEKİLLER

Şekil 1. Zenit, yükseklik ve azimut açılarının yerküre üzerinde gösterimi	3
Şekil 2 Yüzey azimut açısı gösterişi.....	4
Şekil 3 Piroetre	6
Şekil 4 Anemometre	7
Şekil 5 Ortam Sıcaklık Ölçer	7
Şekil 6 Güneşlenme Zamanı Sensörü montaj şematigi	8
Şekil 7 Ülkelerin Meteorolojik amaçlı uzaydaki uyduları	9
Şekil 8 Meteosat III.Nesil Uydusu.....	10
Şekil 9 Ülkelere Göre Rüzgâr Kurulu Güç(2016,GW).....	12
Şekil 10 Türkiye Yenilenebilir Enerji Kaynaklarından Elektrik Üreten Tesislerin Güç Gelişimi.....	17
Şekil 11 Elektrik üretiminde Güneş Enerjisi Teknik Potansiyeli [11].....	18
Şekil 12 Türkiye Güneş Enerjisi Potansiyel Atlası [12]	18
Şekil 13 Türkiye Global Radyasyon Değerleri (KWh/m ² -gün) [12].....	19
Şekil 14 Türkiye Güneşlenme Süreleri (Saat) [12].....	20
Şekil 15 Diyarbakır Güneş Enerjisi Potansiyel Haritası [12]	21
Şekil 16 Diyarbakır Global Radyasyon Değerleri (KWh/m ² -gün) [12]	21
Şekil 17 Diyarbakır Güneşlenme Süreleri (Saat) [12]	22
Şekil 18 Şanlıurfa Güneş Enerjisi Potansiyel Haritası [12].....	23
Şekil 19 Şanlıurfa Global Radyasyon Değerleri (KWh/m ² -gün) [12].....	23
Şekil 20 Şanlıurfa Güneşlenme Süreleri (Saat) [12].....	24
Şekil 21 Gaziantep Güneş Enerjisi Potansiyel Haritası [12]	25
Şekil 22 Gaziantep Global Radyasyon Değerleri (KWh/m ² -gün) [12]	25
Şekil 23 Gaziantep Güneşlenme Süreleri (Saat) [12]	26
Şekil 24 Batman Güneş Enerjisi Potansiyel Haritası [12]	27
Şekil 25 BatmanGlobal Radyasyon Değerleri (KWh/m ² -gün) [12]	27
Şekil 26 Batman Güneşlenme Süreleri (Saat) [12]	28
Şekil 27 Mardin Güneş Enerjisi Potansiyel Haritası[12].....	29
Şekil 28 Mardin Global Radyasyon Değerleri (KWh/m ² -gün) [12].....	29
Şekil 29 Mardin Güneşlenme Süreleri (Saat) [12].....	30
Şekil 30 Yapay sinir ağı- Hücre yapısı.	37
Şekil 31 Diyarbakır farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R ²	51
Şekil 32 Ş.Urfa farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R ²	52
Şekil 33 G. Antep farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R ²	52
Şekil 34 Batman farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R ²	53

Şekil 35 Mardin farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R^2	53
Şekil 36 Solar irradiation giriş verilerinin TBA analizi.....	54

Tablo 1 Yenilenebilir Enerji Göstergeleri 2017	14
Tablo 2 2017 Yılı Yıllık Yatırım/Net Kapasite İlaveleri/Üretim.....	16
Tablo 3 Tahmin İçin Kullanılan Verilerin Sınıflandırılması	35
Tablo 4 Farklı iller için farklı yöntemlerin TBA uygulanmaksızın elde edilen eğitim R^2 değerleri	49
Tablo 5 Farklı iller için farklı yöntemlerin TBA uygulanmaksızın elde edilen test R^2 değerleri	49
Tablo 6 Farklı iller için farklı yöntemlerin TBA uygulayarak elde edilen eğitim R^2 değerleri	50
Tablo 7 Farklı iller için farklı yöntemlerin TBA uygulayarak elde edilen test R^2 değerleri	50

SİMGELER VE KISALTMALAR

Simgeler

a, b, c, d	Ampirik katsayılar
G_{sc}	Güneş sabiti (1367 W/m ²)
ϕ	Enlem açısı
ω	Saat açısı
δ	Deklinasyon açısı
θ_z	Zenith açısı
α	Güneş yükseklik açısı
γ_s	Güneş azimut açısı
γ	Yüzey azimut açısı
H	Aylık ortalama günlük toplam güneş ışıınımı (W/m ² .gün)
H_0	Aylık ortalama atmosfer dışı güneş ışıınım (W/m ² .gün)
S	Güneşlenme süresi (h)
S_0	Aylık maksimum ortalama günlük güneşlenme süresi (h)
I_d	Eğik düzleme gelen yayılı güneş ışıınımı değeri (W/m ² .gün)
I_b	Eğik düzleme gelen direkt güneş ışıınımı değeri (W/m ² .gün)
R^2	Belirlilik katsayısı

Kısaltmalar

DMT	Dünya Meteoroloji Örgütü
WRC	Dünya Radyasyon Merkezi
GA	Genetic Algoritma
KDGA	Kararlı Durum Genetik Algoritma
μ GA	Mikro Genetik Algoritma
mGA	Dağınık Genetik Algoritma
HGA	Hiyerarşik Genetik Algoritma
ML	Machine Learning
ANFIS	Adaptive-Network Based Fuzzy Inference Systems
SVM	Support Vector Machine
ANN	Artificial Neural Network
YSA	Yapay Sinir Ağı
MLP	Multi-Layer Perceptron
DVM	Destek Vektör Makinesi
DVR	Destek Vektör Regresyonu
KPP	Kare Programlama Problemi
KNN	K En Yakın Komşu
ELM	Extreme Learning Machine
RBF	Radyal Bazlı Fonksiyon
TGKBA	Tek Gizli Katmanlı Beslemeli Ağ
W	Watt
M	Metre
MPE	% Ortalama yüzde hata
MAPE	% Ortalama mutlak hata yüzdesi

RSE	Bağıl standart hata
MBE	Ortalama sapma hatası
RMSE	Ortalama hata kareleri kökü
MTG	Meteosat Third Generation
TBA	Temel Bileşen Analizi
EKK	EN Küçük Kareler



1. GİRİŞ

Güneş enerjisi dünya iklimini ve atmosferini en çok etkileyen faktördür. İklim değişimlerinin nesiller üzerindeki etkilerinin artmasıyla beraber üzerinde çalışılması gereken önemli bir konu haline gelmiştir. Bu durumda yer yüzeyine ulaşan güneş ışıınımlarının enerjiye dönüştürülmesi önem kazanmıştır [1],[2].

Yenilenebilir enerjiye dayalı enerji arzı, ülkenin geleceği için çok önemlidir ve güneş enerjisinin bu arzı karşılamada önemli bir rol oynayacağı açıktır. Düşük belirsizlikler ile kurulacak olan güneş enerji santrallerinin fizibilite çalışmalarını tamamlamak için yerinde ölçüm yapılması zorunludur. Güneş ışıınının sağlıklı ölçülmesi yapılacak yatırımın uzun sürede verimli bir şekilde ülke kaynaklarının doğru kullanılmasını sağlayacaktır. Yüksek maliyetli tesislerin olması gereken verimde çalıştırılması için yeterli ölçüm alınamaması durumunda tahmin yöntemleri kullanılarak ülke kaynaklarının boşa kullanılmasının önüne geçilmiş olmaktadır [1],[2].

Güneş enerjisi potansiyelinin belirlenmesi için meteorolojik gözlemler yapılması, teknolojik gelişim ve insan gücü gibi etkenler için yatırım gerekmektedir. Maliyet hesaplamasında; izleme cihazlarının fiyatlandırması, bu cihazların yeterince ve sıklıkla bakım ve kalibrasyonunun yapılamaması, verilerin aktarılmasında ve depolanmasında yaşanan problemler den dolayı izleme istasyonlarının kurulumu ve işletmesi sıkıntılı olmaktadır [1],[2].

1.1 Güneş Işınımı

Sanayileşmeyle birlikte enerji talebi de artmaktadır, geçmiş kaynaklardaki kısıtlı ve çevre duyarlılığı olmayan enerji arzı, yenilenebilir enerji kaynaklarının önemini artırdı. Güneş enerjisine dayalı; dalga, rüzgâr ve biokütle gibi yenilenebilir enerji kaynaklarını kullanmanın birincil koşulu, kapasiteyi doğru olarak belirlemektir. Güneş enerjisini kullanılabilir forma dönüştürmek için, gerekli dönüştürücülerin teknik özellikleri ve fiziksel boyutları ve söz konusu bölge için bu enerji kaynağının gerçekçi sayısal ifadesi yıl boyunca gereklidir. Tahmin yöntemlerinden en az biri, modelleme, coğrafi bilgi sistemleri, hesaplama ve direkt ölçüm, zaman boyutunda güneş enerjisinin sayısal büyüklüğünü anlatmak için gereklidir. Gerçek ölçümlerin yerini tahmin yöntemlerinin alamayacağı tartışılmazdır. Ölçüm dışında geliştirilen yöntemler, ölçümün ve gözlemin doğrudan gerçekleştirilemediği koşullar altında bilgi gereksinimini karşılamayı hedefler. Tahmin yöntemlerinin bütünü, anlık ölçümler, istatistiksel hesaplamalar gibi farklı değişkenler, Angström formülasyonu, uydu

verilerinin gerçek ölçümleri tarafından sağlanan görüntü işleme teknikleri veya coğrafi bilgi sistemleri gibi önceden tanımlanmış algoritmalar gibi eski ölçümlere dayanmaktadır. DMT (Dünya Meteoroloji Örgütü) meteorolojik girdileri, yöntemlerini, ölçüm aralıklarını, birimlerini ve kullanılacak formülasyonları tanımlar. Meteorolojik güneş ışığı süresi, direkt ışınlama, dağınık ışınlama, albedo ve toplam güneş ışınlama değişkenlerinin ölçülmesi önerilmiştir. Tüm bu radyasyon ölçümleri, ışınlama yoğunluğunu zemin yüzeyine paralel bir düzlemden ölçme prensibine dayanmaktadır. Toplam güneş ışınlamı değişkeni, atmosferdeki çeşitli elementler tarafından güneşten herhangi bir engel olmaksızın doğrudan yansıyan ışınlamının toplamıdır. Yatay yüzeyden dolayı dünyadan gökyüzüne yansıyan Albedo radyasyonu bu toplamda yer almamaktadır [3].

Güneş süresinin doğrudan ölçümü, cam kâğıda odaklanmasının bir sonucu olarak, grafik camı üzerinde cam küre lensi bulunan zaman dilimleriyle cam kâğıda odaklanmasının sonucu olarak güneşi yakan küresel bir cihaz olan helyograflar ile ölçülür. Radyasyon ölçümleri, genel olarak, radyometre adı verilen radyometrelerle yapılır. Mekanik olarak işletilen radyometreler arasında aktinometreler veya kaydediciler; elektronik olarak çalışan pirometre veya pirelyometre olarak adlandırılır. Mekanik aktinograflar, enerjiyi cal / cm^2 dakika içinde ölçerken, elektronik radyometreler W / m^2 cinsinden güneş radyasyon yoğunluğunu birim alandaki radyasyon gücü olarak ölçer. DMT'nin önerisine göre en az $120 \text{ W} / \text{m}^2$ radyasyon gücü ölçülebildiğinde, güneşlenmenin gerçekleştiği ve güneşlenme süresinin bu yoğunluğun olduğu zaman aralığı sayılarak dakika veya saat olarak sayıldığı sonucuna varılmıştır. Her ne kadar pirometre toplam güneş ışığını ölçse de, doğrudan güneş ışığını sürekli olarak bloke edecek bir daireyle çevrili olan pirometreler, sadece dağınık ışıktandırmayı ölçmekte ve pirometre olarak adlandırılmaktadır [3].

1.2 Güneş Sabitesi

Güneş, dünyanın kendisi etrafındaki yörüngesi dairesel değildir, bundan dolayı dünya ve güneş arasındaki mesafe % 1.7 oranında değişmektedir. Aralarındaki açı farkı 32° olduğunda, mesafe $1.49 \times 10^{11} \text{ m}$ olur. Mesafenin ortalama değeri alındığında atmosfer dışı güneş ışınlamına “Güneş Sabiti” denir ve G_{sc} . Simgesiyle gösterilir. Bu sabite kcal / m^2 veya W / m^2 birimleri kullanılarak tanımlanmaktadır. Dünya genelinde en önemli araştırmalarda güneş sabiti, CGAbbot tarafından yapılan ölçümler neticesinde $1322 \text{ W} / \text{m}^2$ olarak bulunmuştur. Yapılan birçok çalışmalar sonucunda, Abbot’un

Güneş sabiti için bulunduğu değer 1395 W/m^2 olarak Johnson tarafından düzeltildi. Yakın zamanda uzayda yapılan ölçümler neticesinde Dünya Radyasyon Merkezi (DRM) tarafından hata sınırı %1 oranında güneş sabitini kabul etmiştir [4].


1.3 Güneş Açısı

Ana güneş açılarının bir fonksiyonu olarak, türetilmiş açılar güneş ışığının hesaplanmasını mümkün kılmaktadır. Bu açılar hesaplama yönteminde kolaylık ve doğruluk sağlamaktadır.

1.3.1 Zenit Açısı

Zirve açısı, güneşin doğup battığı, ışınların dünyaya dik olduğu zamandır. Doğrudan güneş ışığı yönünün yatay düzlemin normaliyle yaptığı açıdır. Zirve açısı güneşin doğma ve batma anında $\theta_z=90$ olurken, ışınların dünya yüzeyine dikey geldiği zamanlarda ise $\theta_z=0$ 'dir. Zirve açısı enlem açısı göre aşağıda gösterilen şekilde hesaplanmaktadır [5].

$$\cos\theta_z = \sin\delta \cdot \cos\phi \cos\omega + \sin\delta \sin\phi$$



Şekil 1. Zenit, yükseklik ve azimut açılarının yerküre üzerinde gösterimi [5].

1.3.2 Güneş Yüksekliği Açısı

Güneşin yüksekliği açısı yatay düzlem ile güneş ışığı arasında oluşturduğu açıdır. Bu açı, öğlen vakitlerinde her mevsimde en yüksek değerdedir. Eğim açısı, enlem açısı ve güneş saati açısı referans alınarak aşağıdaki eşitlik oluşturmaktadır.

$$\sin a = \sin\delta \cdot \cos\phi \cos\omega + \sin\delta \sin\phi$$

Yükseklik açısı güneşin doğması ve batması sırasında sıfırdır, Zirve açısı ile toplamı ise doksan derecedir. [5]

$$\theta_z + a = 90^\circ$$

1.3.3 Azimut Açısı Tanımı


Güneşin yönünü hesaplayabilmek için kutup koordinatlarında azimut açısı gereklidir. Dünya ile güneş yön açısı, yatay düzlemin kuzey-güney yönünde çıkıntısının, diğer bir deyişle doğrudan güneş ışığı ile kuzey-güney arasındaki açı farkıdır. Güneydeki azimut açısı değerinin sinüs karşılığı, aşağıdaki korelasyon ile bulunur [5].

$$\sin \gamma_s = \frac{\cos(\delta) \cdot \sin(\omega)}{\sin \theta_z}$$

Güneş ışınlarının kuzey yönüne göre Saat'in dönme yönünde değişimini gösteren açıdır. Saat tam 12'de $\gamma_s = 180^\circ$ olur [5].

1.3.4 Yüzey Azimut Açısının Tanımı

Yüzeyin dikeyinin yerel boylama göre sapmasını gösteren, yüzeyin normali ile kuzey güney doğrultusu arasındaki açıdır. Bu açı -180° ile 180° arasında değişebilmektedir. Yüzey azimut açısı tespit etmek için yüzeye dik gelen ışınların boylama göre sapmasını gösteren ve yüzeyin normali ile kuzey-güney doğrultusundaki fark açısıdır. Açının değeri -180° ile 180° arasında değişiklik gösterebilmektedir.



Şekil 2 Yüzey azimut açısı gösterişi [5].

Bu tanımlamalar doğrultusunda açının doğuya bakan yüzeylerinde $''+''$, batıya bakan yüzeyde ise $''-''$ değer alır [5].

1.3.5 Güneş Yön Açısı

Yüzerin normal açısı ile yeryüzüne doğrudan gelen güneş ışınlarının arasında kalan açığa denir. Açık değerleri bu yönler göre değerler almaktadır, ışınlar dik geliyorsa yön açısı sıfır, paralel ise doksan derecedir. Yön açısı eğik düzlemin yatay düzlem ile yaptığı açı değerine ''s'' denirse eşitlik aşağıdaki gibi hesaplanır [5].

$$\begin{aligned} \cos\theta = & [\sin(\delta) \cdot \sin(\emptyset) \cdot \cos(s) - \sin(\delta) \cdot \cos(\emptyset) \cdot \sin(s) \cdot \cos(\gamma) \\ & + \cos(\delta) \cdot \cos(\emptyset) \cdot \cos(s) \cdot \cos(\omega) \\ & + \cos(\delta) \cdot \sin(\emptyset) \cdot \sin(s) \cdot \cos(\gamma) \cdot \cos(\omega) \\ & + \cos(\delta) \cdot \sin(s) \cdot \sin(\gamma) \cdot \sin(\omega)] \end{aligned}$$

1.4 Radyasyon Ölçümü

Herhangi bir güneş uygulaması yapılmadan önce, bir bölgedeki güneş radyasyonu yoğunluğunu bilmek çok önemlidir. Güneş radyasyonu bilgileri, tasarım ve onarım maliyetlerini en aza indirmek için mümkün olduğunca doğru ve kapsamlı olmalıdır. Her ne kadar birçok mühendislik tasarımında hassasiyet çok önemli olmasa da, bilimsel çalışmalarda hassasiyet önemli bir yere sahiptir. Bazı araştırmacılara göre, güneş verilerinde % 20'lik bir hata güneş enerjisini elektrik enerjisine dönüştüren sistemlerin uygulamalarında % 4 ile % 20 oranında bir değişime neden olmaktadır. Güneş radyasyonu genellikle W/m^2 cinsinden bulunur. Diğer birimler ise aşağıda verilen şekilde kullanılır [5].

$$\frac{1 \text{ Langly}}{hr} = 1 \frac{cal}{cm^2} - hr = 11.63 \text{ W/m}^2$$

1.4.1 Pirometre

Global veya dağınık radyasyonu ölçen bir sensördür. Sensör, yarımkürenin altındaki çift camdan oluşur ve bakır-konsandandın (% 55 bakır,% 45 nikel alaşımı, termal çiftleri olan siyah bir metal) oluşur. Pirometrenin çalışma prensibi, koyu siyah yüzeyin gelen ışığı emmesi sonucunda oluşan elektrik hareket gücünü kullanarak soğuk kısımdan daha yüksek bir sıcaklığa ulaşmasıdır. Meydana gelen bu elektrik hareket gücünün (10 ile 20 mV arasında), belirli bir zaman serisinde integrali alınır ve ulaşılan sonuç global radyasyonun bir ölçümüdür. Tek bir termokuplun çıkışı yaklaşık 22 $\mu V / ^\circ C$ 'dir, mevcut bir voltaj elde etmek ve hassasiyeti artırmak için birçok termokupl (50 veya daha fazla) seri bağlanır. Sensör algılayıcı, yatay bir düzleme düşen

toplam ışıınıı ölçmek için yatay olarak yerleştirilir. Pirometrelerle ölçülen radyasyonu gözlemlemek için voltmetre veya veri kaydedici kullanılmalıdır. Bütün pirometrelerin üzerinde veya kitapçığında bir hassasiyet değeri vardır. Duyarlılık değeri genelde $\mu V/W.m^2$ olarak gösterilir. Voltmetreye bağlantı sonucunda pirometre de ölçülen volt değeri pirometre duyarlılık değeri ile bölünür. Sonuç, pirometreye düşen radyasyon değeridir. Global Radyasyon, pirometreye düşen tüm radyasyonların toplamıdır. Dağılma(Difuse) radyasyonu doğrudan ve yansıyan radyasyonu bloke ederek ölçülür. Doğrudan radyasyon, pirometreye düşen direkt radyasyondur [6].



Şekil 3 Pirometre [6].

1.4.1.1 Anemometre (Yel Ölçer)

Rüzgâr / hava hızını ölçen bir sensördür. Havalandırma tesislerinde ve meteorolojik istasyonlarda kullanılır. Özellikle rüzgârın bilimsel araştırmaları sonucunda camsız termal toplayıcıların ve hibrit toplayıcıların etkisi gözlemlendi. Anemometreler, rüzgâr hızına bağlı olarak her turda bir elektrik sinyali üretir. Bu elektrik sinyali veri kaydediciler vasıtasıyla kaydedilir ve gösterilir. Tüm anemometreler bir ölçüm aralığına sahiptir. Ek olarak, çıkış sinyali bütün anemometrelerin üzerinde veya kendisine ait kılavuza yazılır. Ölçüm aralığı değeri ile birbiriyle bölünmüş çıkış sinyali arasında bir oran vardır, bu oran ölçülen çıkış sinyaliyle çarpılır ve (m / s) cinsinden rüzgâr hızı bulunur. Anemometrenin çıkış sinyalini ölçmek için bir voltmetre veya bir voltmetre veri kaydedici kullanılmalıdır [6].



Şekil 4 Anemometre [6].

1.4.1.2 Ortam Sıcaklık Ölçer

Dış ortam sıcaklığını ölçmek de kullanılır. Çoğu zaman PT100 sıcaklık ölçerler mevcuttur. Bazen, termokupllarda kullanılmaktadır. PT100 sıcaklık ölçer, dört telli direnç ölçüm yöntemine göre direnç çıkışı verir. Termokupllar voltaj çıkışı verir. Dış sıcaklık ölçümleri için sensör beyaz havalandırmalı radyasyon kalkanı ile korunmalıdır. Kalkansız uzun süre kullanılması durumunda, sensöre direkt gelen güneş ışığı nedeniyle hatalar ortaya çıkmaktadır. Çevre sıcaklığı, PV Panel verimliliğinde önemli bir rol oynar. Bazen, PT100 sıcaklık sensörleri direnç voltaj dönüştürücülerinden voltaj çıkışı verir. Sıcaklık ölçümü için NESA TA-A ortam sıcaklığı sensörü PT100 kullanılır. Sıcaklık, anemometre bölümünde açıklandığı gibi bir oran kullanılarak ölçülür [6].




Şekil 5 Ortam Sıcaklık Ölçer [6].

1.4.1.3 Güneşlenme Zamanı Sensörü

Yatay yüzeye gelen doğrudan radyasyon $120\text{W} / \text{m}^2$ 'nin üzerinde olduğunda, anların kaydedilmesini sağlayan sensördür. Kuzey yarımkürede yapılan ölçümler için

kuzeye dikey açılı olarak monte edilir. Güney yarım küredeki ölçümler için yönlendirme Güney'e yapılır. Açı, algılayıcı ile düşey eksen arasındaki ölçüm noktasının coğrafi koordinatlarına göre değiştiği için Türkiye'de enlem kuşağı ortalama 5 derecedir [6].




Şekil 6 Güneşlenme Zamanı Sensörü montaj şematığı [6].

1.4.1.4 Bağıl Nem Algılayıcı(Sensör)

Sensör, ortamın bağıl nem oranını ölçebilir özelliktedir, %0 ile %100 çalışma aralığına sahiptir [6].

1.4.2 Meteorolojik Uydular

Uydular, hava olaylarının küresel olarak araştırılmasını sağlayan uzaktan algılama cihazlarıdır. Dünyanın etrafındaki yörüngelerde hareket ettiklerinde, sensörleri (radyometre) tarafından kaydedilen verileri düzenli aralıklarla yer istasyonlarına gönderirler. Uyduların öne çıkan özelliği ölçüm zorluğu olan ve verilerin elde edilmesinin sıkıntılı olduğu bölgeler için meteorolojik verilerin elde edilmesini sağlamaktadırlar [7].



Şekil 7 Ülkelerin Meteorolojik amaçlı uzaydaki uyduları [7].

1.4.2.1 Meteorolojik Uydu Kullanım Alanları ve Amaçları

Uydu verileri hava tahmini yapan kişiler ve bilimsel araştırmacılar için çok değerli öğrenme kaynaklarıdır. Uydu görüntüleri;

1. En önemlisi gözlemlerin az olduğu alanlarda bilgi sağlar.
2. Dijital hava tahmin modellerine girdi verileri sağlar.

Uydu görüntüleri yukarıda belirtilen maddelere ilave olarak birçok meteorolojik parametreler hakkında bilgi verirler [7].

1.4.2.2 Uydu Tipleri

Meteorolojik amaçlı kullanılan uydular yörüngelerine göre iki sınıflandırmaya ayrılırlar:

- I. Sabit Yörüngeli Uydular
- II. Kutupsal Yörüngeli Uydular

1.4.2.2.1 Sabit Yörüngeli Uydular

Sabit yörüngeli uydular, birincil amaç olarak meteorolojik gözlemler için kullanılmasına rağmen kutupsal yörüngeli uydular, kısa vadeli hava tahmin durumunu, tarımsal gözlem, hava-deniz etkileşimi ve meteorolojik amaçlar için kullanılmaktadır [7].


Uydu üzerinde bulunan pasif sensörler sayesinde, dünya yüzeyinden alınan verileri yerde bulunan istasyonlara aktarmaktadır. Yer istasyonlarında işlenen ham veriler yeniden uyduya aktarılarak kullanıcılara dağıtılır [7].

1.4.2.2.2 Kutupsal Yörüngeli Uydular

Kutupsal yörüngeli uydular sabit yörüngeli uydulara göre çok daha düşük yüksekliklerden nem ve sıcaklık profilleri hakkında daha kesin ve detaylı bilgiler sunmaktadır [7].

1.4.2.2.3 III. Nesil Uydu Programı

III. Nesil uyduları (MTG) 2018 yılından itibaren tüm izleme ve bilgilerin takibi için devreye alınması planlanmıştır. MTG programında 6 adet uydu bulunmaktadır. Bu uydular sadece önceki uyduların devamı olmakla kalmayacak, extra olarak daha ileri teknolojik hizmetler verecek ve maliyeti çok daha düşük olacaktır. MTG programı, dijital hava tahmini ve anlık hava tahmini konularında önemli gelişmeler göstermesi beklenmektedir [7].



Şekil 8 Meteosat III.Nesil Uydusu [7].

1.5 Yenilenebilir Enerji

Küresel çapta elektrik elde etmek için fosil yakıtların kullanılması ile edilmektedir. Fosil yakıtların yenilenmeye enerji olması ve çevreye verdiği olumsuzluklar dikkate alındığında yenilenebilir enerji kaynaklarının fosil yakıtlarının yerini alması gerekmektedir. Sürdürülebilir ir yaşam için mutlaka sürdürülebilir enerji politikalarının hayata geçmesi gerekmektedir. Gelecek nesiller için gelecek ufkunun iyi olması için bu kaçınılmazdır. Bu enerji kaynaklarının kendini yenileme ve tükenme hızından çok daha hızlı bir şekilde kendini yenileyebilen kaynaklar olarak tanımlanabiliyor.

YEK(Yenilenebilir enerji kaynakları); gelgit, hidrojen, biokütle, dalga, jeotermal, hidroelektrik, rüzgâr ve güneş enerjisinden oluşmaktadır [8].

1.5.1 Fotovoltaik Güneş Enerjisi

Güneş enerjisi, PV paneller aracılığı ile dünyaya gelen ışınların elektriğe dönüştürülmesi ile meydana gelmektedir. Yenilenebilir enerji kaynakları içerisinde en hızlı gelişen ve uygulama imkânı bulan enerji türüdür. Maliyetlerin düşmesi ve teşvikler sebebiyle küresele ve ulusal anlamda hızla kurulumlar artmaktadır [8].

Avantaj ve dezavantajları kısaca özetlersek; yenilenebilir olması avantaj iken verimin düşük olması dezavantajdır. Doğal malzeme kullanılması, kaynağın güneş olması dışa bağımlı olmadığı anlamına gelir, temiz bir enerji türü ve ekonomik olması diğer avantajlarıdır. Mevsimsel değişim göstermesi, ilk yatırım maliyetlerinin yüksek olması ve depolama sorunlarında dezavantajlarıdır [8].

1.5.2 Hidroelektrik (Enerji) Santralleri

Doğal kaynak olan suyun akış gücü kullanılır, bu akış gücü sayesinde bir kinetik enerji oluşur, yüksek akış gücü kanallar vasıtasıyla oluşturulur ve türbinlere aktarılır ve türbinler vasıtasıyla elektrik üretimi gerçekleşir. Debinin yüksek olması ve yükseklik üretim için en önemli avantajlardır [8].


Başlıca avantaj ve dezavantajları aşağıda sıralanmıştır;

- ✓ Birincil amaç sulama olup enerji de üretilmektedir.
- ✓ Devreye alma ve devreden çıkarma kolaydır.
- ✓ Dışa bağımlılık yoktur.
- ✓ Doğal olmasından dolayı çevreye zararı olmaz.

- Kurulum süreçleri uzun olmakla beraber ilk yatırım fiyatları yüksektir.
- Yağış durumu üretim kapasitesinin etkiler.
- Doğal afetler açısından risk taşımaktadır.

1.5.3 Rüzgâr Türbin enerjisi

Rüzgârın, dünyanın dönüşü ve oluşan basınç ile hava akımlarının yer değiştirmesi yoluyla oluşmaktadır. Büyük Rüzgâr türbinlerinin rüzgâr alan yerlere kurulması ile üretim yapılmaktadır. İhtiyaca göre birçok türbin üretilmektedir. En çok bulunan çeşitleri; yatay eksenli düşey eksenli, eğik eksenli, küçük tip ve Mikro türbinlerdir. Şekil 9’da görüleceği üzere Türkiye rüzgar enerjisi konusunda yatırımları bakımından çok geç kalmış ve kurulu güç bakımından ilk 10 ülke arasına girmemektedir [9].



Şekil 9 Ülkelere Göre Rüzgâr Kurulu Güç(2016,GW) [9].

Rüzgâr enerjisi avantaj ve dezavantajları bakımından aşağıda sıralanmıştır;

- ✓ Yenilenebilirdir.
 - ✓ Birim fiyatlar düşmektedir.
 - ✓ Dışa bağımlılık yoktur.
 - ✓ Doğal olmasından dolayı çevreye zararı yok gibidir.
 - ✓ %95 oranında her yerde bu enerji türünden faydalanabilir.
- Büyük yapılar olması nedeniyle görsel kirlilik oluşturur.

- Geniş alanlara kurulmaktadır
- Rüzgâr yön değiştirmesi ve kuşların göç yollarına denk gelmesi durumlarında toplu ölümlere sebep olabilmektedir.
- Gürültü kirliliği oluşturmakta ve verim düşüktür [9].

1.5.4 Jeotermal Isı Enerjisi

Farklı yöntemler ile elde edilen jeotermal kaynakların kullanılması ile üretilir. Birçok amaçla kullanılmakta (soğutma, ısıtma, elektrik), özellikle kaplıca olarak yerel turizme katkı sağlamaktadır [9].

Başlıca avantaj ve dezavantajları aşağıda sıralanmıştır;

- ✓ Suyun elde edilmesi için ilave yatırıma gerek yoktur, direk yer altından elde edilmektedir.
 - ✓ Suyun ısıtılması için ilave yakıtı ihtiyaç yoktur.
 - ✓ Dışa bağımlılık yoktur.
 - ✓ Doğal olmasından dolayı çevreye zararı olmaz.
 - ✓ Verimlilik oranı yüksektir.
- Bazı kimyasallar içermesi, ortaya çıkan akışkan maddeler zararlı olabilmektedir.
 - Tükenebilir bir kaynaktır.
 - İletim verimsiz olabilir, bundan dolayı yerleşim yerine yakın olması gerekmektedir [9].

Biokütle, Hidrojen ve Dalga enerjileri gün geçtikçe kullanımının artan ve temiz enerjilerdir. Bu enerji türlerinin üretime dâhil edilmesi çeşitlilik açısından faydalı olacaktır [9].

1.6 Yenilenebilir Enerjiye Küresel Bakış

Yenilenebilir enerji yılı olarak ta adlandırabileceğimiz 2017 yılı, güç kapasitesinde en büyük artışın olması, teknolojik gelişmeler, maliyetlerin azalması ve yükselen yatırımlar bu yılı yenilenebilir enerji bakımından ön plana çıkarmaktadır. Küresel çapta temiz hava stratejileri ve buna bağlı olarak yargısal düzenlemeler,

dijitalleşmenin trend haline gelmesi, siyasi politikalar yenilenebilir enerjinin daha çok hayatımızı girmesine olanak sağladı. Devlet ve özel sektörler yenilenebilir enerji alanında alt yapı yatırımları, teşvikler dolayısıyla yönelmektedir. Özellikle gelişmekte olan ülkeler enerji çeşitliği açısından bu alana ciddi anlamda yoğunlaşmışlardır, yargısal ve bürokratik engelleri kaldırmak için çalışmaktadır. Yenilenebilir enerji kaynakları küresel boyutta 2016 yılında toplam tüketilen enerjinin %18,2'sine karşılık gelirken, modern kısmı %10,4'e karşılık gelmektedir. 2017 yılında yenilenebilir enerji kaynaklarına yatırımı artıran ülke sayısı artmış ve buna yönelik olumlu politikalar geliştirilmiştir. Yenilenebilir enerji sektöründe özellikle Fotovoltaik sistemler birinciliği almakta, rüzgâr ve diğer yenilenebilir enerji kaynaklarını geride bıraktı [10].

Isıtma ve soğutma alanında yenilenebilir enerji alanında gelişim yetersiz kalmakla birlikte 2015 yılı itibari ile dünya çapında tüketimin ancak %10.3'ünü karşılayabildi.

Ulaşım alanında yetersiz kalan yenilenebilir enerji sektördeki enerji payını artırmak için epey uğraşılması gerekmektedir. Mevcut durumda %3.1 gibi düşük bir kısmını ancak kullanmaktadır [10].

2017 yılındaki üretim artışının yüksek olması ve bir önceki yıla oranla %9'luk artış Fotovoltaik ve Rüzgâr güçlerindeki artışın etkisi ile olmuştur. Bu artışların etkisi ile küresel kapasitede %70'lik bir gelişim sağlandı [10].

Güneş enerjisi, yenilenebilir enerji kaynakları içerisinde gelişim kapasitesinin %55 gibi büyük bir payı alarak en çok yatırım yapılan enerji türü oldu. Buda yeni yatırımların daha çok bu alanda devam edeceğinin bir göstergesi olarak görülebilir [10].

		2016	2017
Yatırım			
Yenilenebilir Enerji ve Yakıtta Yeni Yatırımlar	Milyar ABD Doları	274	279.8
Enerji			
Yenilenebilir Enerji Kapasitesi(Hidro dâhil)	GW	2.017	2.195
Yenilenebilir Enerji Kapasitesi(Hidro dâhil değil)	GW	922	1.081
Hidroelektrik Kapasitesi	GW	1.095	1.114
Biyogaz	GW	114	122
Jeotermal Güç Kapasitesi	GW	12,1	12,8
Güneş PV Kapasitesi	GW	303	402
Rüzgâr Enerji Kapasitesi	GW	487	539

Tablo 1 Yenilenebilir Enerji Göstergeleri 2017 [10]

Yenidünya düzeninde küresel dünyanın ortak sorunu olan enerji verimliliği ve temiz enerji 2017 yılı itibari ile aynen önemini devam ettirmektedir kadar önemli ki dünya çapında birçok ülke politikalarının merkezine yenilenebilir Enerji'yi koymaktadır. Özelde ve genelde kirliliğin azaltılması, yeniş kollarının açılması, enerji güvenliği ve ekonomik gelişimin en önemli faktörlerinden biri olarak sayılmaktadır. Bu bağlamda 2017 yılı içerisinde 157 ülke enerji verimliliği için gelişim hedeflerinin belirlenmesi için çalışmalar başlattı, 145 ülke de ise ikinci adım olan politikaların düzenlenmesine geçildi [10].

Enerji politikaları teşvik amaçlı olarak her geçen gün yenilenebilir enerjinin önündeki yasal engellerin kaldırılması ve enerjiye alım garantisin getirilmesi üzerine düzenleme yapılmaktadır, ekonomik gelişim içinde olan Afrika ve brezilya gibi ülkeler alım garantisi için yasalarında değişikliklere devam etmektedir.29 ülkede 2017 yılı itibari ile ihaleler gerçekleştirilmiştir. Şebeke entegrasyonları artıkça sistem güvenilirliğini, değişken yapıdaki yenilenebilir enerjiyi ve bunun piyasa şartlarının sağlanmasını oluşturmak gerekmektedir [10].

Fotovoltaik Sistemler 2017 yılı itibari ile güç üretme açısından enerjinin lokomotif görevini üstlendi. PV panel teknolojisinde yaşanan gelişmeler rekabetin artışı gelişimi tetiklemektedir.


Yenilenebilir enerji yatırımları bakımından gelişmekte olan ülkeler gelişmiş ülkeleri yapılan yatırımlar bakımından geçtiği görünmektedir. Yapılan yeni yatırımlar ile (50 MW'tan üstü hidroelektrik yatırımı barındırmayan), yıllık 200 milyar ABD doların üstüne çıktı. Yenilenebilir enerji kaynaklarından olan güneş ve rüzgâr için 2016 yılına göre %2'lik bir artışla 279,8 milyar dolarlık bir yatırım gerçekleşmiş oldu. Gelişim içinde olan ülkeler yenilenebilir enerji yatırımları bakımından 2015 yılında gelişmiş ülkeleri geçmiş ve 2017 yılı için aradaki farkı artırmıştır. Çin'inin etkisininin büyük olması ile birlikte gelişen Ülkeler 'in dünya çapında payı %63 olarak gerçekleşmiştir. Gelişim içerisinde olan ülkelerde %20 oranında yatırımlar artış göstermiş ve bu ülkelerin payı artış ile birlikte 177 milyar dolar olmuştur. Gelişmekte olan ülkelerde ise %19 oranında düşüş yaşanmıştır. Küresel toplamda payları 103 milyar dolar olmuştur [10].

	1	2	3	4	5
Yenilenebilir Enerji ve Yatırım(Hidro dâhil Değildir.)	Çin	ABD	Japonya	Hırvatistan	Almanya
Jeotermal Güç Kapasitesi	Endonezya	Türkiye	Şile	İzlanda	Honduras
Hidroelektrik Kapasitesi	Çin	Brezilya	Hindistan	Angola	Türkiye
PV Güneş	Çin	ABD	Hindistan	Japonya	Türkiye
Rüzgâr Enerjisi Kapasitesi	Çin	ABD	Almanya	İngiltere	Hindistan

Tablo 2 2017 Yılı Yıllık Yatırım/Net Kapasite İlaveleri/Üretim [10].

1.7 Yenilenebilir Enerji ve Türkiye’deki Gelişim Süreci


Şekil 11’de Türkiye’de yenilenebilir enerji kaynaklarının 2009 yılında rüzgâr enerjisi ile gelişmeye başladığını 2014 ve 2015 yılına kadar da güneş enerjisinden üretim yapılmaya yeni başlandığını görmekteyiz. 2017 yılında yapılan yatırımlar ile güneş enerjisinin katkısı bariz bir şekilde artmıştır. 2016 yılına göre 2017 yılında 2587,5 MW artış ile yenilenebilir enerjinin toplam üretilen güç’ katkısını ciddi anlamda artırmıştır. 2017 yılı itibarı ile yenilenebilir enerjinin %30’luk bir katkısı olmaktadır [11].



Şekil 10 Türkiye Yenilenebilir Enerji Kaynaklarından Elektrik Üreten Tesislerin Güç Gelişimi [11].


Türkiye yenilenebilir enerji kaynaklarına destek konusunda gelişmekte olan ülkeler sınıfında yer almaktadır. Ulusal ve yabancı yatırımların teşvik edilmesi için bir dizi teşvik çalışması yürütülmektedir, özellikle yenilenebilir enerjinin önündeki yasal engellerin kaldırılması ve kurulumda yaşanabilecek sorunların düzeltilmesi için gerekli kanunlar hazırlanmıştır. Yenilenebilir enerjiden elde edilen üretim için devlet alım garantisi uygulayarak yatırımcının teşvik edilmesi sağlanmıştır. Ülkemiz rüzgâr ve güneş enerjisi açısından yüksek potansiyel taşımaktadır, temiz hava politikaları da yenilenebilir enerjiye yönelmenin farklı bir boyutunu ifade etmektedir [11].

Türkiye enerji güvenliği açısından dışa bağımlılığı azaltmak ve enerjisini çeşitlendirmek için yenilenebilir enerji potansiyelinin artırması gerekmektedir. Özellikle 2009-2015 yılları arasında üretim miktarı 15,5GW ‘tan 31,7 GW değerlerine kadar yükselmiştir. Özellikle 2017 yılında güneş enerjisine yapılan teşvikler ve yatırımlar ile yenilenebilir enerjini kurulu gücü 38,9 GW değerlerine kadar ulaşmıştır [11].



Şekil 11 Elektrik üretiminde Güneş Enerjisi Teknik Potansiyeli [11].

Şekil 12’de Türkiye Güneş enerjisi potansiyel bakımından kendisine en yakın olan ülkelerden bile %30 oranında daha fazla potansiyele sahiptir. Türkiye’nin konumu ve güneşlenme sürelerinin yüksek olması bu sonucu ortaya çıkarmaktadır.




Şekil 12 Türkiye Güneş Enerjisi Potansiyel Atlası [12]

Türkiye’de 2014 ve 2017 yılları arasında güneş enerjisinin kurulu gücü 40 MW’ tan 3420 MW’ ta kadar yükselmiştir. 2009 ve öncesinde güneş enerjisi termal sistemler kullanılarak su ısıtmak için kullanılmaktaydı. 2010 yılı itibari ile güneş enerjisinin elektrik üretmek amaçlı da kullanılması hız kazanmıştır. 2023 yılı hedefleri doğrultusunda yenilenebilir enerji için kalkınma planı hazırlanmış ve bu plan çerçevesinde enerjinin %15’nin karşılanması (ısıtma ve Soğutma) hedeflenmiştir.


Türkiye kendisinde bulunan potansiyeli değerlendirmek ve güneş enerjisinden yeteri kadar faydalanmak zorundadır [12].

Türkiye'nin Güneş enerjisi potansiyeli (şekil 13) 2023 yılı referans alındığında yaklaşık 500 bin MW ihtiyacının olacağı tahmin edilmektedir. Buna göre mevcut potansiyel ile karşılanabilmektedir ancak mevcut imkân ve maliyetlerin yüksek olmasından dolayı yapılması mümkün değildir. Buna rağmen mevcut potansiyel den maksimum üretim elde edilmesi gerekmektedir [12].

Şekil 13'te görüleceği üzere Güney Doğu Anadolu bölgesi ve Akdeniz bölgesi potansiyel bakımından önde yer almaktadırlar. Karadeniz ve Marmara ise güneşlenme sürelerinin en az olduğu bölgelerdir. Güneş enerjisi potansiyeli haritasında görüleceği üzere Türkiye yüksek potansiyele sahip olmasına rağmen ekonomik ve teknolojik kısıtlardan kaynaklı olarak bu potansiyellini kullanamamaktadır. Türkiye'de potansiyelin değerlendirilmesi için yerli üretimin artırılması ve yatırımcının desteklenmesi gerekmektedir [12].



Şekil 13 Türkiye Global Radyasyon Değerleri (KWh/m²-gün) [12]




Şekil 14 Türkiye Güneşlenme Süreleri (Saat) [12]


Şekil 14 ve 15'te görüleceği üzere Türkiye'de güneşlenme süreleri ve global ışıınım değerleri yaz ayları olan Haziran, Temmuz ve Ağustos aylarında en yüksek değerlere ulaşmaktadır.

1.8 Güneydoğu Anadolu Bölgesi'ndeki Beş İl için Güneş Enerjisi Potansiyeli


Şekil 16,19,22,25 ve 28'de Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin İllerine ait güneş enerjisi potansiyel haritaları verilmiştir. Tüm illerin Türkiye genelinde potansiyel olarak en yüksek kapasiteye sahip olduğu görülmektedir. Renk skalası ve üretim potansiyeline ait ölçeklendirme aşağıda görülmektedir. Bu ölçeklendirmeye göre tüm illerde $\text{KWh/m}^2\text{-yıl}$ değerleri 1600-1650 ve üstünde bir kapasite değeri görülmektedir.



Şekil 15 Diyarbakır Güneş Enerjisi Potansiyel Haritası [12]




Şekil 16 Diyarbakır Global Radyasyon Değerleri (KWh/m²-gün) [12]




Şekil 17 Diyarbakır Güneşlenme Süreleri (Saat) [12]


Şekil 17 ve 18’de görüleceği üzere Diyarbakır ili için güneşlenme zamanı ve süreleri 12 ay boyunca farklılık göstermektedir. Güneş ışıınımı açısından Mayıs, Haziran ve Temmuz aylarında, güneşlenme süreleri açısından ise Haziran, Temmuz ve Ağustos aylarında en yüksek değerler elde edilmektedir. En düşük aylar; Ocak, Kasım ve Aralık ayları olarak ölçülmektedir.



Şekil 18 Şanlıurfa Güneş Enerjisi Potansiyel Haritası [12]




Şekil 19 Şanlıurfa Global Radyasyon Değerleri (KWh/m²-gün) [12]




Şekil 20 Şanlıurfa Güneşlenme Süreleri (Saat) [12]


Şekil 20 ve 21’de görüleceği üzere Şanlıurfa ili için güneşlenme zamanı ve süreleri 12 ay boyunca farklılık göstermektedir. Güneş ışıınımı açısından Mayıs, Haziran ve Temmuz aylarında, güneşlenme süreleri açısından ise Haziran, Temmuz ve Ağustos aylarında en yüksek değerler elde edilmektedir. Güneş ışıınımı açısından en düşük aylar; Ocak, Kasım ve Aralık, güneşlenme süreleri açısından ise Ocak, Şubat ve Aralık ayları olarak ölçülmektedir.



Şekil 21 Gaziantep Güneş Enerjisi Potansiyel Haritası [12]




Şekil 22 Gaziantep Global Radyasyon Değerleri (KWh/m²-gün) [12]




Şekil 23 Gaziantep Güneşlenme Süreleri (Saat) [12]


Şekil 23 ve 24’de görüleceği üzere Gaziantep ili için güneşlenme zamanı ve süreleri 12 ay boyunca farklılık göstermektedir. Güneş ışıınımlı açısından Mayıs, Haziran ve Temmuz aylarında, güneşlenme süreleri açısından ise Haziran, Temmuz ve Ağustos aylarında en yüksek değerler elde edilmektedir. En düşük aylar; Ocak, Şubat ve Aralık ayları olarak ölçülmektedir.



Şekil 24 Batman Güneş Enerjisi Potansiyel Haritası [12]




Şekil 25 Batman Global Radyasyon Değerleri (KWh/m²-gün) [12]




Şekil 26 Batman Güneşlenme Süreleri (Saat) [12]


Şekil 26 ve 27’de görüleceği üzere Batman ili için güneşlenme zamanı ve süreleri 12 ay boyunca farklılık göstermektedir. Güneş ışınlamı açısından Mayıs, Haziran ve Temmuz aylarında, güneşlenme süreleri açısından ise Haziran, Temmuz ve Ağustos aylarında en yüksek değerler elde edilmektedir. Güneş ışınlamı açısından en düşük aylar; Ocak, Kasım ve Aralık, güneşlenme süreleri açısından ise Ocak, Şubat ve Aralık ayları olarak ölçülmektedir.



Şekil 27 Mardin Güneş Enerjisi Potansiyel Haritası[12]



Şekil 28 Mardin Global Radyasyon Değerleri (KWh/m²-gün) [12]



Şekil 29 Mardin Güneşlenme Süreleri (Saat) [12]

Şekil 17,20,23,26,29’da görüleceği üzere Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin illerinde Radyasyon değeri açısından Mayıs, Haziran ve Temmuz ayları en yüksek değere sahiptir.

Şekil 18,21,24,27,30’da görüleceği üzere Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin illerinde Haziran, Temmuz ve Ağustos ayları güneşlenme sürelerinin en uzun olduğu aylardır.

2 KAYNAK ARAŞTIRMASI

Literatür taraması yapılarak Güneş ışıınımı konusunda geçmişten bu yana yapılan yöntemler araştırılmıştır. Ampirik yöntem, Makine öğrenmesi, Bulanık mantık ve Genetik Algoritma metotları en çok kullanılan metotlardır. Bu çalışmada on farklı yöntem kullanarak geçmişte yapılan yöntemler ile karşılaştırmalı bir şekilde analiz yapacağız. Tahmin yöntemleri açısından teknolojinin gelişmiş olması ve uygulamaların artması verimlilik açısından hata yapma oranını düşürmek için en isabetli analizlerin doğru yöntemler ile yapılması gerekmektedir. Çalışmada kullanacağımız yöntemler; Lasso, Lineer, Bayesian Ridge, SVM Lineer, RandomForest, Bagging, Ridge, Huber, SVM RBF ve Adaboost yöntemleridir.

2.1 Ampirik Yöntem Kaynak Araştırması

1920'li yıllarında Angström tarafından lineer modelin geliştirmesiyle güneş ışıınımı tahmini ile ilgili ilk çalışma yapılmıştır. Bundan sonra yapılan araştırmalar belli coğrafyalara özgü model oluşturmak ya da modelleri geliştirmek için yapılmıştır [13]. Güneş ışıınımı tahmin hesaplamalarında; Ogelman ve ark. [14] 2.dereceden polinom kullanarak model oluşturmuş, Glover ve McCulloch [15] enlem koordinatlarını kullanmış, Barbaro ve arkadaşları [16] Dağınık ışıınım ölçümlerine yeni bir anlam kazandırmış, Öztürk ve Kılıç [17]. Ampirik a ve b katsayılarının tespitinde diğerlerinden ayrı yöntem kullanmış, Benson ve ark. [18] iklim veri datasına yer vermiş, Gopinathan ve ark. [19] a ve b katsayılarının bulunması için rakımı referans almış, Newland ve ark. [20] yeni bir logaritmik model geliştirmiş, Ecevit ve Fakıoğlu [21] sadece gün sayısı değerini dikkate almış, Samuel ve ark. [22] yatay düzleme gelen güneş ışıınımı için 3. Dereceden denklem geliştirmiş, Aksoy ve ark. [23] farklı iklim coğrafyasında bulunan illerde (Antalya, Ankara, Konya, Samsun, Şanlıurfa ve İzmir) aylık ortalamaya göre güneş ışıınım modeli oluşturulmuştur. Mansell ile Elagib [24] coğrafi parametreler kullanarak üstel ilişki kurmuştur, Bakırcı ve ark. [25] Beşinci dereceden eşitlik kullanmış, Ülgen ve ark. [26] sıcaklık parametresini dâhil etmiş, Sarı ve ark. [27] Orta Karadeniz bölgesi için yaptıkları çalışmada beş il'i (Amasya, Çorum, Ordu, Samsun ve Tokat) kapsayan ikinci ve üçüncü dereceden denklem geliştirmiş, Louche ile ark. [28] Akdeniz Bölgesi için saatlik, günlük ve yıllık ışıınım değerleriyle güneş ışıınımı tahmini için modeller oluşturmuş, Kallioğlu ve ark. [29] Niğde ili için yatay düzleme gelen günlük tüm, dağınık ve direkt güneş ışıınımını hesaplamaya yönelik model geliştirilmek için çalışmalar yapmışlardır.

Bütün bu çalışmaların temel nedeni, güneş ışınlamalarının sağlıklı bir şekilde ölçmek için mevcut çalışma alanlarının verilerine en yakın değerleri bularak hata oranını azaltmaktır. Bu fikirle, birçok farklı yöntem geliştirilmiştir ve asıl gaye bu yöntemlerin istatistiksel olarak uyumunu sağlamak olmuştur.

2.2 Makine Öğrenmesi Kaynak Araştırması

Günümüzde, makine öğrenmesi (ML) belki de güneş tahmininde en popüler yaklaşımdır. Farklı niteliklerine rağmen, ML algoritmaları aynı çerçeveyi paylaşırlar: öğrenmenin sınıflandırma, regresyon ve öngörmeyi gerektirdiği verilerden öğrenme modelleri ve model parametreleri kavramına dayanırlar. Bu anlamda, ML algoritmaları güneş tahmini için çok uygundur. Güneş tahmin uygulamaları, tarihsel verilerden oluşan bir veri setine dayanan nokta değerleri veya tahmin aralıkları için tahmin modelleri oluşturmayı içerir. Quej ve ark. [30] Güneş radyasyonunu tahmin etmek için ANFIS, SVM ve ANN yöntemlerini kullandılar, günlük maksimum ve minimum hava sıcaklığı, dünya dışı güneş radyasyonu ve yağış gereksinimlerine verilerine göre SVM'nin diğer tekniklerden daha iyi performansa sahip olduğu tespit edilmiştir. Chiteka ve ark. [31] Zimbabve'deki küresel güneş ışığını tahmin etmek için YSA'ları kullanıldı. Modelin girdi değişkenleri olarak enlem ve boylam coğrafi verileri ile nem basıncı, açıklık indeksi ve ortalama sıcaklık meteorolojik verileri kullanılmıştır. En iyi YSA yapısı gizli katmandaki 10 nöron ile elde edildi, giriş ve çıkış katmanları için bir tansig transfer fonksiyonu önerildi. Ağ'ın R_2 katsayısı % 99.894 oranında gerçekleşmiştir. Rani ve ark. [32] sıcaklık, nem, ay ve gün sinir ağına girdi olduğunda modelin daha doğru olduğunu bulmuşlardır. Veriler iki alt gruba ayrıldı: eğitim seti ve test seti. Elde edilen model, kök ortalama kare hatası (RMSE) ve ortalama mutlak yüzde hatası (MAPE) sırasıyla % 0.9429 ve 9.1754 değerleri olarak bulunmuştur. Tarih ve ay girdi olarak kullanıldığında model daha az doğruydı. Wang ve ark. [33] Kısa vadeli güneş ışınlamı tahmini için yapay sinir ağı ve zaman serisi analizi kullanmıştır. Sinirsel ağ modelinde girdi olarak dağınık radyasyon, sıcaklık, bağıl nem ve süre kullanılmış, iki transfer fonksiyonu olan tang-sigmoid ve log-sigmoid ile çift gizli katmanlar uygulanmıştır. Sonuçlar, güneş ışınlamasının doğru tahminini göstermiştir. Spesifik olarak, modelin katsayısı % 99.12 ve kök ortalama karesi 0.0331'dir. Angela ve ark. [34] Kampala verilerine uygulamak için yapay bir sinir ağı kullanarak günlük küresel güneş ışınlamının aylık ortalama tahminini gerçekleştirmiştir. Teğet sigmoid transfer fonksiyonu, bir gizli katman ve 65 nöron ile kullanıldı. Hatanın ortalama kare değeri 0.521 MJ / korelasyon katsayısı (R)

0.965 idi. Makale, modelin geçerli olduğu ancak kesinliğin yüksek olduğu sonucuna vardı, çünkü sinir ağına girdi sadece güneş saatlerini içeriyordu. Melliti ve ark. [35] İtalya'daki 24 saatlik güneş ışınlamını tahmin etmek için yapay sinir ağlarında Çok Katmanlı Perceptron'u (MLP) araştırdı. Girişler günlük ortalama ışınlam ve günlük hava sıcaklığının ortalamalarına dayanıyordu. Makale, en iyi modelin bir girdi ve iki gizli katmanla elde edildiğini gösterdi. Güneşli bir gün için korelasyon katsayısı % 98 ile % 99 arasındaydı; ancak bulutlu bir günde % 94 ile % 95 arasındaydı.

Yukarıda verilen çalışmaların amacı ölçümlerin en iyi şekilde yapılarak çalışma yapılan yerel bölgenin verilerine en yakın değerlerin bulunması için hata oranını düşürmektir.

2.3 Bulanık Mantık ve Genetik Algoritma Kaynak Araştırması

Rivington ve ark. [36] Güneş ışınlamı tahmin yöntemlerinden hava'nın sıcaklık durumuna göre iki, güneşlenme vaktinin değişimine göre yapılan modellemenin karakteristik ve performans davranış biçimlerini birleşik krallıkta bulunan 24 istasyon için detaylandırmışlardır. Yıllık veriler ile hataların zaman açısından dağılımının ortalamalarını ile bulanık mantık açısından çoklu değerlendirmeleri referans alarak test sonuçlarını karşılaştırmışlardır. Sistemli mevsimsel hatalar oluşmasına rağmen Güneşlenme süresinin güneş ışınlamına dönüşümünün en iyi tahminler ürettiği tespitinde bulunmuşlardır. Şen ve ark. [37] tahimleme yöntemlerinde bulanık mantık yaklaşımını kullanmak için güneşlenme sürelerinin ölçümlerinden faydalandılar. Bulanık mantık yöntemini ülkemizin batısındaki üç farklı yere uyguladılar. Buldukları bu yeni yöntem ile güneşlenme süreleri ve rastgele ışıma için bütün ülkelerde kullanılacağını iddia ettiler. Şen ile Tan [38] ülkemizin kuzeybatı kesiminde detaylı olarak ölçülen güneş ışınlamının saatlik, günlük ve aylık istatistiksel analizleri nedeniyle, istatistiksel modeller açısından yol gösterdiğini ifade etmişlerdir. Aynı karakteristik özelliklerin tekrar yorumlanması ile bu modellerin tüm dünyada geçerli olduğunu belirtmişlerdir. Modellerde bulunan 3 karakteristik özelliğin parabolik eşitlikler formatında görüldüğünü tespit etmekle beraber, parametreler arasında anlamlı bir ilişki olduğunu da belirtmişlerdir. Aylık ortalama saatlik güneş ışınlam verileri ile bu eşitlikler kullanılarak ışınlam miktarının tahmin edilmesinin mümkün olduğunu belirtmişlerdir. Chow ile Wong [39] Hong Kong şehri için günlük ortalama ışınlam tahmininde bulunmuşlardır. Aylık ortalama saatlik verilerinin ışınlam tahminlerini tartışmışlardır. Hong Kong şehri için iki farklı parametrik modeli incelemiş olup modellerin tahmin edilmesinde ölçülen

verileri karşılaştırmışlardır. Farklı araştırmacılar tarafından güneş ışıının belirlenmesinde aynı metotlar da kullanılmıştır [40,41,42].

Herrera'nın [43] çalışmasında belirlenmiş bir bulanık kontrolörün kural alt yapısının oluşumunda üyelik fonksiyonları üyelik fonksiyonlarının belirlenmesi için genetik algoritmaları kullanmıştır. Araştırma da parametrelerin reel değerleri kullanılmıştır. Lee ve arkadaşları [44] çalışmalarında Genetik algoritmaları, üyelik fonksiyonlarının sayısının tespiti için bulanık mantık kontrolörleri, bulanık mantık kurallarının ve kural altyapısının oluşturulmasında kullanmışlardır. Belarbi ve ark. [45] Çalışmalarında, ikili tabanda kromozomları kodlanmıştır. Bulanık mantık kontrolörü dizaynı da ysa kullanmış ve ağırlık değeri eğitimi için genetik algoritmaları kullanmıştır. Park ve Ark'ının [46] çalışmalarında belli başlı parametreler kullanılmıştır, tepe noktalarının ve üyelik fonksiyon sayısının belirlenmesi ile kural altyapısının oluşturulmasında, bu durum ortaya esnek bir model ortaya çıkarmıştır. Cheong ve Ark. [47] tarafından da benzer bir çalışma yapılmıştır.

3 MATERYAL VE YÖNTEM

Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin illeri için güneş enerjisi potansiyeli belirlemek için Meteoroloji genel müdürlüğünden meteorolojik veriler alınarak on farklı yöntem ile hangi yöntemin her bir İl'e ne kadar uyumlu olduğu incelenmiş ve araştırılan bölgenin ışıınım sürelerine göre en yakın modeli bulmak için farklı metodlar kullanılmıştır. Kaynakların verimli kullanılması gelişmekte olan ülkeler için çok önem arz etmektedir, bundan dolayı kaynakların boşa gitmemesi adına farklı güçlüklerle elde edilen ölçümler kullanılarak bölge uygunluk analizlerinin yapılması çok önem kazanmaktadır. Beş il için 10 farklı yöntem kullanılmıştır. Bu yöntemler; Lasso, Lineer, Bayesian Ridge, SVM Lineer, RandomForest, Bagging, Ridge, Hubber, SVM RBF ve Adaboost yöntemleridir. Aynı yöntemlere TBA(Temel Bileşenler Analizi) uygulanarak yöntemlerin sonuçları gözlemlenmiştir.

Şehir	Test Sınıf Yılları		Tahmin Sınıf Yılları	
	Periyod	Toplam Yıl	Periyod	Toplam Yıl
Diyarbakır	2008-2010	2	2010-2018	8
Şanlıurfa	2008-2010	2	2010-2018	8
Gaziantep	2008-2010	2	2010-2018	8
Batman	2008-2010	2	2010-2018	8
Mardin	2008-2010	2	2010-2018	8

Tablo 3 Tahmin için kullanılan verilerin sınıflandırılması

3.1 Ampirik Yöntemler ve Hesaplama

Güneş radyasyonu verileri, gelen ortalama radyasyonu tahmin etmek için en iyi bilgi kaynağıdır. Güneş ışıınımı veya bulutluluk tahmini, ışıınımı tahmin etmek için ampirik yöntemler kullanılarak yapılabilir. Ortalama güneşli saatlere veya olası güneşli saatlerin ortalama yüzdesine ilişkin veriler, birçok ülkedeki yüzlerce istasyondan geniş ölçüde bulunmaktadır ve veriler genellikle Campbell-Stokes cihazlarıyla elde edilir. Literatür taraması incelendiğinde, küresel güneş radyasyonu öngörüsü için birçok model çalışmanın olduğu görülmektedir. Bu modeller içerisinde en yaygın olanı ise Angström-tip eşitliklerden oluşmaktadır [48] [49]:

$$\frac{\bar{H}}{\bar{H}_c} = a' + b' \left(\frac{\bar{n}}{\bar{N}} \right)$$

Formülde; $\bar{H}$, aylık ortalama günlük güneş radyasyonu $\bar{H}_c$, günlük dünya dışı yatay yüzeye gelen güneş radyasyonu; $\bar{n}$, günlük güneşlenme süresi aylık ortalama, $\bar{N}$ maksimum aylık ortalama günlük güneşlenme süresi(Mümkün olan), a' ve b' ampirik sabitlerdir [48] [49].

Parametre sayısı arttıkça, korelasyon çoklu doğrusal bir regresyon haline gelir.

Ecevit Akınoğlu tarafından İkinci dereceden bir polinom için eşitlik aşağıdaki gibi önerilmiştir [50].

$$\frac{H}{H_0} = a + b \left(\frac{n}{N} \right) + c \left(\frac{n}{N} \right)^2$$

Bahel ve arkadaşları tarafından Üçüncü dereceden bir polinom için eşitlik aşağıdaki gibi verilmiştir [51].

$$\frac{H}{H_0} = a + b \left(\frac{n}{N} \right) + c \left(\frac{n}{N} \right)^2 + d \left(\frac{n}{N} \right)^3$$


3.2 Makine Öğrenmesi ve Kullanılan Yöntemler

Makine Öğrenmesi (Machine Learning; ML), yazılım programlarının açık programlama olmadan sonuçları tahmin etmek için kullanılan algoritmalar en iyi sonuç vermektedir. Makine öğrenmesinin dayandığı ana ilke, girdi verileri üretmek için algoritmalar kullanmak ve çıktıları yeni veriler ortaya çıktıkça güncellerken, elde edilen çıktıları tahmin etmek için istatistiksel analizler kullanılır. Makine öğrenmesi algoritmaları genellikle iki şekilde kategorize; denetlenir veya denetlenmez. Algılanan algoritmalar, girdi verisini ve istenen çıktı verisini bulmak için makine öğrenme bilgisine sahip test ve Eğitim verilerinin; ayrıca algoritma eğitimi sırasındaki tahminlerin doğruluğu hakkında geribildirim sağlar. Test modeli, modelin hangi değişkenleri veya özellikleri analiz edeceğini ve tahminler geliştirmek için kullanacağını belirler. Eğitim tamamlanması ile birlikte algoritma, öğrenilen bilgileri yeniden uygulayacaktır. Kontrolsüz algoritmaların elde edilen sonuçlar ile eğitilmesi gerekmez. Tekrarlı bir yöntem olan derin öğrenme(DP), gözlem ve sonuç analizlerini yapmak için kullanılmalıdır. Kontrolsüz öğrenme algoritmaları, görüntü tanıma,

metinden konuşma vb. kontrollü öğrenme metotlarından extra karmaşık analiz görevleri için kullanılır. Bu ysa çok sayıda eğitim verisi örneğini tarayarak ve birçok değişken parametre arasında hassas korelasyonları otomatikman tespit ederek çalışır. Verileri yorumlamak eğitim setinin bir kez eğitilmesi yeterlidir. Bu algoritmalar yeni yeni uygulanabilir hale geldi, çünkü öncesinde çok fazla eğitim verisine ihtiyaç duyuluyordu [52].

3.2.1 Yapay Sinir Ağları

Yapay Sinir Ağı (YSA), beyin gibi biyolojik sinir ağını temel alan karmaşık bir sistemdir. Beyin, elektro-kimyasal sinyallerle iletişim kuran yaklaşık 100 milyar nörona sahiptir. Nöronlar sinaps adı verilen kavşaklarla bağlanır. Her bir nöron, hücre gövdesine ulaşmak için sürekli olarak gelen sinyalleri alan, diğer nöronlarla binlerce bağlantı alır. Elde edilen sinyallerin toplamı belirli bir eşiği geçerse, aksondan bir yanıt gönderilir. YSA, biyolojik sinir ağına hesaplama yansımasını yeniden oluşturmaya çalışsa da, nöronların sayısı ve biyolojik sinir ağlarında kullanılanların sayısı ve karmaşıklığı yapay bir nötr ağıdakilerden çok daha fazla olduğu için karşılaştırılmaz. Yapay sinir ağları modellemesi, insan beyninden ilham alınarak yapılmıştır, sinir hücresinin (nöron) yapısı algoritmalar geliştiren, modelleyen ve öğrenen sistemlerdir. Modelleme ve kontrol konularında yapay sinir ağları geniş uygulama alanları bulmaktadır [52].



Şekil 30 Yapay sinir ağı- Hücre yapısı [52].

Yapay sinir ağları öncelikle eldeki verileri kullanılarak eğitilirler ve sonrasında eğitim sürecinde kullanılmayan veriler ile test edilir. Yapay sinir ağları eğitimi süreci uzun sürse de; hızlı karar verebilme, hem doğrusal hem de doğrusal olmayan sistemleri modellemede hataları öğrenme, genelleme ve tolerans gösterme

yeteneklerinden dolayı çok çeşitli uygulama alanları bulmuştur [52]. YSA uygulama alanları birçok yeni teknolojik alt yapıda kullanılmaktadır, özellikle; Tıp bilimi, görüntü işleme, otomatik kontrol, sinyal işleme ve sistem modellenmesi için kullanılır [53]. YSA'lar yapısal olarak farklılık göstermektedir. Genellikle katman sayısı üç 'tür. Bunlar: giriş katmanı, çıkış katmanı ve gizli katmandır. Giriş katmanında bulunan hücre sayısı, yapay sinir ağında bulunan giriş verisi sayısına eşittir. Yapay sinir ağından alınacak olan bilgi sayısı çıkış katmanındaki hücre sayısıdır. Düğüm sayısı gizli katmanda deney sonucunda bulunur. Hücre sayısı ve aralarındaki bağlantı sayılarının artması sonucunda yapay sinir ağında öğrenmek kapasitesi artar ama eğitim artar. YSA'ların matematiksel farklılıkları, eğitimlerinde kullanılan algoritmalarından ve hücre çıktısında kullanılan aktivasyon fonksiyonundan kaynaklanır. Doğrusal olmayan modellemenin oluşması aktivasyon fonksiyonlarının üstel fonksiyonları içermesi sonucunda elde edilir. D girişli yapay sinir ağı, m gizli nöronlar ve tek bir lineer çıkış ünitesi, bir giriş vektöründen x , bir çıkış y 'ye kadar doğrusal olmayan parametrelili bir haritalamayı tanımlar. Gizlenmiş m birimlerinin her biri genellikle teğet hiperbolik fonksiyon $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ ile ilişkilidir. Parametre vektörü $w = (\{w_j\}, \{w_{ji}\})$ doğrusal olmayan haritalamayı yönetir ve eğitim veya öğrenme aşaması adı verilen bir aşamada tahmin edilir. Bu aşamada, YSA bir n giriş ve çıkış örneği kümesi içeren veri seti kullanılarak eğitilir. Bu aşamada, YSA bir n giriş ve çıkış örneği kümesi içeren veri seti kullanılarak eğitilir. Genelleme aşaması olarak adlandırılan ikinci aşama, test veri setinde ysa'nın genelleştirme yeteneğinin, yani eğitim aşamasında görülmeyen örneklerle karşı karşıya kaldığında doğru çıktılar vermesinin değerlendirilmesinden meydana gelir. Güneş radyasyonu için, çıkış $\hat{k} * (t + h)$ ile giriş $\{k * (t), k * (t - 1), \dots, k * (t - p)\}$ arasındaki ilişki aşağıdaki şekilde verilir:

$$\hat{k} * (t + h) = \sum_{j=1}^m w_j f \left(\sum_{i=0}^p w_{ji} k * (t - i) \right)$$

Yukarıdaki denklemde gösterildiği gibi, ysa modeli, zaman serisi tahmin problemleri için doğrusal olmayan otoregressif (AR) bir modele eşdeğerdir. Modelin inşasına özen gösterilmelidir, çünkü çok karmaşık bir ysa eğitim verilerinden kolayca yararlanabilir. YSA'nın karmaşıklığı, gizli birimlerin sayısı veya tersine w vektörünün boyutuyla ilişkilidir. YSA karmaşıklığını kontrol etmek için budama veya

Bayes usulü düzenleme gibi farklı teknikler kullanılabilir. Eğitimi durdurmadan önce bir maksimum başarısızlık parametresi olan Levenberg-Marquardt (Newton'un yöntemine yaklaşma) öğrenme algoritması, ysa modelinin parametrelerini tahmin etmek için yoğun olarak kullanılır. Maksimum başarısızlık parametresi, bir dizi karakteristik tahmin başarısızlığının ardından öğrenme adımlarını sınırlayan bir düzenleştirme aracına karşılık gelir ve sonuç olarak model karmaşıklığını kontrol etmek için bir araçtır [54, 55]. Birçok çalışma, ysa ile örneğin Kalman filtresi veya bulanık mantık gibi diğer araçlar arasındaki eşleşmenin, kazancın genellikle daha yüksek olduğunu doğrulamaktadır [56].

3.2.2 Destek Vektör Regresyonu (SVR)

Burges ve Vapnik tarafından geliştirilen çok önemli bir öğrenme stratejisi olan Destek Vektör Makinesi (DVM), sınıflandırma ve regresyon için etkili bir kernel-tabanlı araçtır ve bu model makine öğrenmesi algoritmalarındaki ilkelere dayandığı için çok güçlüdür [57].

Hiper uzayda doğrusal olmayan Destek VR $f(x) = w^T \phi(x) + b$ ile belirtilen bir regresyon fonksiyonu bulunur. Bu fonksiyon “ ϵ - etkisiz” kayıp elementi kullanılarak elde edilir. DVR, aşağıdaki Kare Programlama Problemi’ni (KPP) çözerek elde edilir [57]:

$$\begin{aligned} \min_{w,b,\epsilon,\epsilon^*} & \frac{1}{2} \|w\|^2 + C(e^T \epsilon + e^T \epsilon^*) \\ \text{s.t. } & (\phi(A) + eb) - Y \leq e\epsilon + \epsilon, \epsilon \geq 0e \\ & Y - (\phi(A)w + eb) \leq e\epsilon + \epsilon^*, \epsilon^* \geq 0e \end{aligned}$$

Denklemden belirtilen C değeri önceden belirlenmiş bir değerdir, bu değer hataların belirlenmesi ve regresyon fonksiyonu arasındaki ayarlamayı sağlayan bir denge parametresidir. ϵ ve ϵ^* örneklerin ϵ -tüneline girişleri denetleyen yapay değişkenlerdir, denklemden kullanılan e ise birim vektördür. a ve a^* çarpanları Lagrange çarpanları olarak adlandırılır, KPP’in kuralı aşağıdaki eşitlikte gösterilir [57]:

$$\begin{aligned} \max_{a,a^*} & -\frac{1}{2} (a^* - a)^T K(A, A^T) (a^* - a) + Y^T (a^* - a) + e^T (a^* + a) \\ \text{s.t. } & e^T (a^* + a) = 0 \\ & 0e \leq a, a^* \leq Ce \end{aligned}$$

KPP (2) çözüldükten sonra, $a^{(*)} = (a_1, a_1^*, a_2, a_2^*, \dots, a_n, a_n^*)$ 'yı ve b katsayılarını kullanarak aşağıdaki şekilde regresyon fonksiyonu bulunur,

$$f(x) = \sum_{i=0}^n (a^* - a)K(x_i, x) + b$$

Burada, $K(x_i, x) = (\phi(x_i) * \phi(x))$ eşitliği kernel fonksiyonunu belirtmektedir. Bu eşitlik ile hiper uzayda nokta çarpımı bulunur. a ve a^* Lagrange çarpanları ve $a_i a_i^* = 0, i = 1, 2, \dots, n$ 'ı sağlamaktadırlar. $f(x)$ Fonksiyonu, sadece Lagrange çarpanları $a_i \neq 0$ veya $a_i^* \neq 0$ olan örnekler tarafından belirlenir. Eğitim setinin girdi ve çıktılarını, sırası ile $A = (x_1, x_2, \dots, x_n)$ ve $Y = (y_1, y_2, \dots, y_n)$ değerleri belirler [57].

3.2.3 Huber Regrasyonu

Huber regresyonu, aykırı değerlere karşı dayanıklı olan bir regresyon tekniğidir. Bu fikirde geleneksel en küçük kareler yerine farklı bir kayıp fonksiyonu kullanılmaktadır. Şu şekilde çözülmektedir [58];

$$m_{i=1}(y_i - x_i^T)$$

$\beta \in R_n$ Değişkeni değeri için, kayıp (ϕ) , $M > 0$ eşğine sahip Huber fonksiyonudur.

$$\phi(u) = \begin{cases} u^2 & \text{eğer } |u| \leq M \\ 2Mu - M^2 & \text{eğer } |u| > M \end{cases}$$

Bu fonksiyon, küçük artıklar için en küçük kareler ile Huber fonksiyonunda hata aynıdır, ancak büyük artıklarda, hata değeri değerin karesi ile orantılı olarak artmaktan daha çok doğrusal olarak artar [58].

3.2.4 Ridge ve LASSO Regrasyon

En başta Hoerl ve Kennard olmak üzere ridge regresyonu hakkında çok sayıda çalışma yapılmıştır. En küçük kareler yönteminde görülen ilerleyişler ridge regresyonunda tekrarlanmaktadır. En küçük kareler ile ridge regresyonu arasındaki

temel fark k^* parametresidir. Regresyon katsayılarının hesaplanması için küçük bir yanlışlık sabiti ilgileşim matrisinin köşegen değerlerine eklenir. Aşağıda verilen formülasyonda hesaplanır [59].

$$Z = (I_k + k * (X'X)^{-1})^{-1}$$

Ridge regresyonu kullanım olarak farklı amaçlar için kullanılmaktadır, gereksiz değişkenler, E.K.K. β tahmin sayısından daha küçük değişkenden daha küçük değişkenlerde ve regresyon katsayılarında oluşan kararsızlıkların grafiksel olarak gösteriminde kullanılmaktadır [59].

LASSO Regresyonu; LASSO yönteminin tahminlerde başarılı olduğu simülasyon sonuçlarında görülmektedir, büzülme modelleri olarak adlandırılan LASSO ve Ridge regresyonları tahmin edicileri arasında denge sağlamaktadır, bundan dolayı da değişik cezalandırmalar kullanılır. Ridge ve LASSO aynı sonuçları vermektedir [59].

LASSO yönteminde değişkenlerin bir alt kümesi kullanılmaktadır fakat Ridge Regresyonu için model içerisinde bulunan bütün değişkenler kullanılmaktadır. Modellerde ortak önem seçilen parametrelerdir. Her iki yöntemin amaç fonksiyonları arasında bir fark vardır, burada regresyon katsayısı için cezalandırma yapılırken değişik yol kullanılır. LASSO yöntemi için cezalandırma katsayıların mutlak değer toplamı kullanılırken Ridge regresyonu için katsayıların kareleri toplamı kullanılır [59].

3.2.5 Bayesian Ridge Regresyonu

LASSO ve Bayesian Ridge regresyonları arasında belirgin bazı farklılıklar bulunmaktadır. İlk olarak, λ -bağımlı bir güvenilirlik eşiği için, $a(\lambda)$ 'ya dayanan çıkarım daha bağımsızdır ve λ 'nin küçük değerleri için yanlış pozitifler ortaya çıkarmaktadır. İkincisi, λ için fenotip permütasyona dayalı sınır, ridge regresyonu için çok daha düşüktür. Bu, Bayesian LASSO ve Bayesian Ridge regresyonları tarafından kullanılan farklı büzülme öncelikleri ile açıklanabilir. Bayes ridge regresyonunda bulunan Gaussian, tüm etkileri bakımından LASSO'dan önce Laplacian'lardan daha ağır büzülür. Böylece, sıfır hipotezi altında, üstünde yanlış pozitif görünmeyen λ -değeri daha küçük olur. Bunun bir sonucu olarak, yüksek colLineer locus tespitinin Bayesian Ridge regresyonu ile daha kolay tespit edilmesidir [60]

Ridge regresyonunda, β tahminini bulmak için en küçük kareler kullanılarak elde edilmektedir:

$$\hat{\beta} = \arg \min (||y - \mu 1 - X\beta||^2 + \sigma ||\beta||^2)$$

σ Değeri büyüdükçe components bileşenleri sıfıra doğru büzülür [60].

3.2.6 Bagging Regresyonu

Yöntem 1996 yılında kullanılmıştır, Breiman tarafından geliştirilen yöntem Bagging (bootstrap aggregating) olarak isimlendirilmektedir. Öncelikle bir topluluk oluşturmak için bir veri seti ele alınır ve bootstrap örneklemelerine tahminciler eklenmesi ile oluşturulur. Yöntem, uygulamaya ait örnekler için iadeli seçim yaparak metod geliştirir. Geliştirilen metod ile elde edilen sonuçlarda değişik sayılarda örneklemeler oluşabilmektedir. Regresyon ve sınıflandırma ağaçlarını birbirinden ayıran en temel özellikler; birisi için ortalama alınması, diğeri için ise oylama ile belirlenmesidir [61][62][63].

Bagging yönteminde tahminci önemlidir, tahminci değişkeni ile geçerli tahmin oranı da artabilir. Yöntemin daha verimli kullanılması için yanlılık oranının düşük olması ve varyans miktarının yüksek seçilmesi en doğru uygulamadır. İlave olarak Bagging yönteminin deney sonuçları bakımından diğr ağaç yönlerine göre daha iyi sonuç sağlamaktadır. Bagging yöntemi çok basit olamamakla beraber yorumlama açısından farklı ağaç modellerinin oluşması bootstrap örneklememelerinin kullanılmasından kaynaklanmaktadır. Benzer ağaç içeren örneklemeler yine oluşan hatalarında benzer olmasına sebep olacaktır [61][62][63].

3.2.7 Random Forest Regresyonu

Random Forest en popüler ve en güçlü makine öğrenme algoritmalarından biridir. Random Forest regresyonu yöntemini Leo Breiman geliştirmiştir(2001). HO'nun rasgele alt grup seçiminin yapılması için geliştirdiği random Subspace yöntemi ile 1996 yılında kendi geliştirdiği Bagging yöntemlerinin birleşiminden oluşmaktadır. Yöntemin gelişiminde en çok etkilenilen kişiler Amit ve Geman'dır. Özellikle etkilendikleri çalışmaları ise 1997 yılında düğümler üzerinden yapılan en iyi ayrımların rastgele seçimler üzerinden yapılması ile ilgili çalışmalar olmuştur [64].

Random Forest regresyon yöntemi tahmin etme ve yorumlama açısından en doğru sonuçlar elde edilmesini sağlar, makine öğrenmesi yöntemleri değerlendirildiğinde bu yöntem bu açılardan öne çıkmaktadır. Bu yöntem tahmin bakımından daha doğru genellemeler yapılmasını sağlar. Random Forest yönteminde yanlılık oranının düşük olması çok büyük ağaç yapılarının oluşmasına olanak sağlar,

bununla beraber yöntemde kesinlik artar ve korelasyon düşük olur. Farklı oluşan ağaç yapılarının oluşması da elde edilen topluluğun düşük korelasyonlu olmasını sağlamaktadır [64].

Bir Öğrenme yöntemi olarak Random Forest farklı regresyon ve sınıflandırma ile kararlı orman topluluklarını oluşturmak için karar ağaçlarını kullanmaktadır. Bu çerçevede yapılan tahmin karar ormanı oluşturulurken ortaya çıkan veriler toplanarak elde edilir. Regresyon yönteminde ağaçlar, az sayıda birim kalana kadar bölünür [64].

3.2.8 AdaBoost Regresyonu

Adaboost yöntemi 1996 yılında Freund ve Schapire tarafından geliştirilmiştir. Bu yöntemde kullanılan veri setleri için farklı ağırlıklar uygulayarak elde edilen ağaç topluluklarından tahminler yürütülmektedir. Yöntemde kullanılan metod itibari ile veri setine eşit ağırlıklar uygulanmaktadır, karar ağacını büyümesi ile beraber ağırlıklar değişmeye başlar, hatalı sonuçlarda ağırlık artırılır, bu zorunlu durumlarda ağaçlar kendini revize etme özelliği elde eder. Yöntem için oluşturulan bazı algoritmalar; Tekil ağaç, tahmin yapılırken kullanılan birleştirici metod ve ağırlık değiştirme metotlarıdır. Bu algoritmaların farklı olması yöntemlerde kullanılan seçimlerden kaynaklanmaktadır [65].

3.2.9 Lineer Regresyon (LR)

LR'da, Y Değişkeni tahmin edilmeye çalışılırken, X_1, X_2, X_n tahmin edicileri arasında doğrusal bir ilişki içerisinde olduğu hakkında varsayımda bulunur. X ve Y değişkenleri arasında doğrusal bir ilişki olduğunun varsayılmasına rağmen gerçekte düzgün doğrusal bir ilişki yoktur. Buna rağmen doğrusal bir yöntemle reel fonksiyona yaklaşılabılır [66].

$$Y = \beta_0 + \beta_1 X + \epsilon$$

Yukarıda formülü dikkate aldığımızda sonuç değişkeninin sadece bir tek tahmin edici değişken ile hesaplanmasını doğrusal regresyon olarak adlandırılmaktadır. Çoklu regresyonda sonuç değişkeni birden fazla tahmin edici değişken ile hesaplanmaktadır. Formülde belirtilen β_0 ve β_1 değerleri bilinmeyen sabitler olarak adlandırılmaktadır, ϵ ise hata sayısını temsil etmektedir. Bilinmeyen sabitleri bulmak için LR kullanarak tahmin edilir [66].

3.3 Temel Bileşen Analizi (TBA)

Temel bileşen analizi (TBA), veri setindeki varyasyonların çoğunu koruyarak verilerin boyutsal 'lığını azaltan matematiksel bir algoritmadır. Bu indirgemeyi, verilerdeki varyasyonun maksimum olduğu temel bileşenler adı verilen yönleri tanımlayarak gerçekleştirir. Birkaç bileşen kullanarak, her örnekleme, binlerce değişken için farklı değerler yerine nispeten az sayıda örnekleme ile gösterilebilir. Örneklemeler daha sonra çizilebilir, böylece örneklemeler arasındaki benzerlik ve farklılıkları görsel olarak değerlendirmek ve örneklemelerin gruplandırılıp gruplandırılmayacağını belirlemek mümkündür [63].

Burada analizdeki asal amaç mevcut verinin çok daha az sayıda değişkenle ifade edilmesini sağlayacak dönüşümün belirlenmesini amaçlar. Dönüşüm ile beraber elde edilen değişkenler başlangıç değişkenlerin temel(ana) bileşenleri olarak adlandırılır. Varyans değeri en büyük olan, ilk temel bileşen, geriye kalanlar ise azalacak şekilde sıralanmaktadır [67].

TBA Avantajları:

- ❖ TBA, çok boyutlu verilerin görsel gösterilmesi ve analizi için kullanılabilir
- ❖ TBA, çok boyutlu verileri yaklaşık olarak ve daha az boyutlu veriyle temsil eder.
- ❖ TBA, boyut azaltmada çok faydalı bir yöntemdir
- ❖ TBA, orijinal veriler için dik olan en büyük varyans yönleri bulup orijinal verileri bu koordinat sisteminde gösterir.
- ❖ TBA, makine öğrenmesi olarak, verilerin boyutunu azaltabilir, az değişken TBA özellikleri modelleme için önemsiz olabilir, bu şekilde modelleme ile ilgili hesaplama hızlandırabilir.
- ❖ TBA, veri sıkıştırma için de kullanılabilir.

TBA, istatistiksel bir metot olmakla beraber bir veri setindeki örüntünün tanımlanması ve veri setinin açıklanmasında da kullanılmaktadır. TBA verinin sıkıştırılmasına boyut azaltarak imkân vermektedir. Üstelik boyut azaltılırken veri kaybı da yaşanmamaktadır. Ayrıca veri içindeki benzer ve farklı desenlerin tanımlanması için de kullanılabilir [68].

TBA yöntemi d boyutlu n örnekli bir veri kümesi $X = [x_1, x_2, x_3, \dots, x_n]$ için kovaryans matrisi aşağıdaki denklemde verilmiştir [69].

$$\Sigma = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T = \frac{1}{n} XX^T$$

Buradaki $\bar{x}$ değeri verinin ortalama değerini belirtmektedir.

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n (x_i)$$

Kovaryans matrisin öz değer ve öz vektörlerinin belirlenmesi, öz değer ve öz vektör ayrıştırma yöntemi ile bulunur. r (en büyük değer) sayısı kadar öz değer seçilerek p dönüşüm matrisi, bu r tane öz değere karşılık öz vektör olarak oluşturulur [70].

Çalışmada kullanılan yöntemler; finanstan, ekonomiden, mühendislik gibi birçok alanda tahmin yapma yöntemleri olarak kullanılmıştır. Bu seçilen yöntemlerden bazıları başka çalışmalarda güneş ışınımının tahmini içinde kullanılmıştır. Kullanılan yöntemlerin amacı bu alanda yapılan diğer çalışmalar ile Güneydoğu Anadolu illerine uygulanması sonucu elde edilen sonuçların karşılaştırmasını amaçlamaktadır. Genel olarak güneş ışınımı tahmininde kullanılan yöntemlerin karşılaştırılması amaçlamaktadır [70].

3.4 Hata Doğrulamasının istatistiksel değerlendirilmesi

Literatürde regresyon modelleri için performans analizlerinin istatistiksel yönden değerlendiren test metotları bulunmaktadır. En çok kullanılan 6 metot aşağıda verilmiştir. Ortalama hata yüzdesi (MPE) ölçüm sonucu elde edilen değer ile regresyon modelleri ile hesaplanan değer farkının yüzdelik değeri olarak bulunur. İdeal değerın sıfır olması için değer aşağıdaki gibi hesaplanır [70]:

$$MPE = \frac{1}{k} \sum_{i=1}^k \left(\frac{H_c - H_m}{H_m} \times 100 \right)$$

Ortalama mutlak hata yüzdesi (MAPE), regresyon modelleri ile hesaplanan değer ile ölçüm sonucu elde edilen değer ile arasındaki yüzdesel sapmanın ortalama mutlak değeridir. İdeal değerın sıfır olması için değer aşağıdaki gibi hesaplanır [70]:

$$MAPE = \frac{1}{k} \sum_{i=1}^k \left(\left| \frac{H_c - H_m}{H_m} \right| \times 100 \right)$$

Sapma hatasının ortalaması (MBE), uzun süreçte modellerin performansı hakkında bilgi sağlar. İdeal değerın sıfır olması için değer aşağıdaki gibi hesaplanır [70]:

$$MBE = \frac{1}{k} \sum_{i=1}^k (H_c - H_m)$$

Mutlak ortalama sapma hatası (MABE) İdeal değerın sıfır olması için değer aşağıdaki gibi hesaplanır [70]:

$$MABE = \frac{1}{k} \sum_{i=1}^k |H_c - H_m|$$

Karekök hata hesabı (RMSE) için kısa dönem performansı hakkında regresyon modellerinin çalışma prensiplerini verir. İdeal değerın sıfır olması için değer aşağıdaki gibi hesaplanır [70]:

$$RMSE = [\frac{1}{k} \sum_{i=1}^k (H_c - H_m)^2]^{1/2}$$

R^2 teorisinde artıkların toplam karesi ne kadar düşük ise uyumluluk o kadar yüksek olmaktadır. Değişken sayısının artması ile beraber payda düşecek, R^2 düşmeyeceğinden uyumluluk oranı iyileşecektir. Etkisi ihmal edilebilen değişkenler modele dâhil edilmeyerek düzeltilmiş R^2 kullanılmaktadır. Düzeltilmiş R^2 normal R^2 'den farklı olarak gereksiz eklenen değişkenleri cezalandırır [70].

$$R^2 = 1 - (1 - R^2) \frac{(n - 1)}{(n - p - 1)}$$

P:bağımsız değişken sayısı, n: Örneklem büyüklüğü

R^2 'nin temellini oluşturan artık kareler toplamının uzaklıklar kareler toplamı; $1-R^2$ olarak ifade edilmektedir. $1-R^2$ ifadesi içinde bağımsız değişken ve örneklem büyüklüğü bulunan orantı ile çarpılması sonucunda bulunur. Bağımsız değişkenin artması paydanın küçülmesini sağlayarak R^2 değerinin 1'in üzerine çıkması sağlanmaktadır. Gereksiz değişkenlerin cezalandırılması ile düzeltilmiş R^2 bulunur. Düzeltilmiş olan bu indeks R^2 'ye göre daha iyi bir uygunluk indeksi elde edilir [70].

4 ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Güneydoğu Anadolu bölgesinde yoğun güneş alan 5 il için meteorolojiden alınan veriler kullanılarak; Güneş ışıınımı, Nem, Sıcaklık ve rüzgâr hızı gibi bileşenlerin tahmin yöntemleri üzerindeki etkileri analiz edilmektedir. Tahmin yapmak için 10 farklı yöntem kullanılmıştır. Bu yöntemler kısaca; Lasso, Lineer, Bayesian Ridge, SVM Lineer, RandomForest, Bagging, Ridge, Hubber, SVM RBF ve Adaboost yöntemleridir. TBA uygulayarak ve TBA uygulanmaksızın; eğitim ve test analizleri için R^2 değerine ait sonuçlar hesaplanmıştır. Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin illeri için TBA uygulanmaksızın elde edilen eğitim ve test sonuçlarına göre R^2 değerinin en iyi olduğu yöntem tablo 4,5,6,7’de de görüleceği üzere Lineer regresyondur. TBA uygulandığında tüm iller için R^2 değerinde belirgin iyileşme tablo-6 ve tablo-7’de açık bir şekilde görünmektedir. Beş il içinde TBA uygulandığında eğitim ve test R^2 sonuçlarına göre SVM Lineer yönteminin en iyi sonuç verdiği görülmektedir. Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin illeri için tablo 4,5,6,7’de sonuçlar kıyaslandığında TBA uygulayarak ve TBA uygulanmaksızın en düşük R^2 sonuçlarının elde edildiği yöntemin AdaBoost yöntemi olduğu görünmektedir. Tahmin yapmak için kullanılan yöntemlerin çıktıları dikkate alındığında 5 il içerisinde yöntem bazlı karşılaştırmada en iyi sonuçların Diyarbakır ilinde en düşük değerlerin de Mardin ilinde elde edildiği görünmektedir.

Çalışmada lineer regresyon yönteminin iyi sonuç vermesinin nedeni ampirik güneş ışıma modelinin benzeri olması ve güneş ışıının tahmini için yeterli olmasıdır. Kullandığımız yöntemlerde giriş parametrelerinin pca analizi göstermektedir ki en etkili parametre güneş ışıınıdır, kullandığımız diğer parametrelerin etkisi çok azdır onlar

olmadan da iyi bir tahmin yapılabilir. Karşılaştırılan makine öğrenme yöntemlerinin lineer regresyon ya da ampirik modelden daha iyi sonuçlar vermesi için etkisi az olan nem, sıcaklık, rüzgar hızı yerine farklı ve daha etkin parametrelerin (bulutluluk oranı) gibi girişte kullanılması ya da bu verilere bağlı olarak daha etkin yeni özelliklerin türetilmesi gerekmektedir.

4.1 Farklı İller için TBA uygulayarak ve TBA uygulanmaksızın Elde Edilen Sonuçlar

Çalışmada kullanılan yöntemlerden elde edilen sonuçlar, tablo ve grafik şeklinde özetlenmiştir. Beş il için elde edilen R^2 sonuçları işlenerek karşılaştırmalı olarak analizler yapılmıştır.

Tablo 4 Farklı iller için farklı yöntemlerin TBA uygulanmaksızın elde edilen eğitim R^2 değerleri

Yöntem/il	Diyarbakır	Ş.urfa	G.Antep	Batman	Mardin
Lasso	0.940564	0.92175272	0.91234708	0.90294144	0.8935358
Lineer	0.949261	0.93027578	0.92078317	0.91129056	0.90179795
Bayesian Ridge	0.944824	0.92592752	0.91647928	0.90703104	0.8975828
SVM Lineer	0.944773	0.92587754	0.91642981	0.90698208	0.89753435
RandomForest	0.944737	0.92584226	0.91639489	0.90694752	0.89750015
Bagging	0.944601	0.92570898	0.91626297	0.90681696	0.89737095
Ridge	0.882238	0.86459324	0.85577086	0.84694848	0.8381261
Hubber	0.819113	0.80273074	0.79453961	0.78634848	0.77815735
SVM RBF	0.804453	0.78836394	0.78031941	0.77227488	0.76423035
AdaBoost	0.765533	0.75022234	0.74256701	0.73491168	0.72725635

Tablo 5 Farklı iller için farklı yöntemlerin TBA uygulanmaksızın elde edilen test R^2 değerleri

Yöntem/il	Diyarbakır	Ş.urfa	G.Antep	Batman	Mardin
Lasso	0.92927723	0.9106916	0.9013989	0.892106	0.8828133
Lineer	0.93786986	0.9191124	0.9097337	0.900355	0.8909763

Bayesian Ridge	0.93348611	0.9148163	0.9054815	0.896146	0.8868118
SVM Lineer	0.93343572	0.9147670	0.9054326	0.896098	0.8867639
RandomForest	0.93340015	0.9147321	0.9053981	0.896064	0.8867301
Bagging	0.93326578	0.9146004	0.9052678	0.895935	0.8866024
Ridge	0.87165114	0.8542181	0.8455016	0.836785	0.8280685
Hubber	0.80928364	0.7930979	0.7850051	0.776912	0.7688194
SVM RBF	0.79479956	0.7789035	0.7709555	0.763007	0.7550595
AdaBoost	0.75634660	0.7412196	0.73365620	0.7260927	0.71852927


Tablo 6 Farklı iller için farklı yöntemlerin TBA uygulayarak elde edilen eğitim R^2 değerleri

Yöntem/il	Diyarbakır	Ş.urfa	G.Antep	Batman	Mardin
Hubber	0.9687809	0.9494053	0.93971749	0.93002968	0.92034187
SVM Lineer	0.9777388	0.9581840	0.94840666	0.93862927	0.92885188
Bayesian Ridge	0.9731687	0.9537053	0.94397365	0.93424197	0.92451028
Lasso	0.9731161	0.9536538	0.94392270	0.93419154	0.92446038
Ridge	0.9730791	0.9536175	0.94388673	0.93415594	0.92442515
Lineer	0.9729390	0.9534802	0.94375085	0.93402146	0.92429207
SVM RBF	0.9087051	0.8905310	0.88144398	0.87235693	0.86326988
Bagging	0.8436863	0.8268126	0.81837579	0.80993893	0.80150207
Random forest	0.8285865	0.8120148	0.803728992	0.795443126	0.787157261
AdaBoost	0.78849899	0.7727290	0.76484402	0.75695903	0.749074041

Tablo 7 Farklı iller için farklı yöntemlerin TBA uygulayarak elde edilen test R^2 değerleri


Yöntem/il	Diyarbakır	Ş.urfa	G.Antep	Batman	Mardin
Hubber	0.9499696	0.93097024	0.92147055	0.91197085	0.90247115
SVM Lineer	0.9587536	0.93957853	0.92999100	0.92040346	0.91081593
Bayesian Ridge	0.9542722	0.93518679	0.92564407	0.91610135	0.90655862
Lasso	0.9542207	0.93513631	0.92559410	0.91605190	0.90650969
Ridge	0.9541843	0.93510068	0.9255588	0.91601699	0.90647515
Lineer	0.9540470	0.93496607	0.9254256	0.91588513	0.90634466
SVM RBF	0.8910603	0.87323917	0.8643285	0.85541796	0.84650736

Bagging	0.8273041	0.81075804	0.8024850	0.79421196	0.78593892
Random forest	0.8124975	0.79624757	0.7881226	0.77999762	0.77187265
AdaBoost	0.77318833	0.757724563	0.74999268	0.742260797	0.73452891




Şekil 31 Diyarbakır farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R^2

Şekil 32’de Diyarbakır ili için eğitim ve test sonuçları beraber verilmiş olup en yüksek değer işaretlenmiştir.




Şekil 32 Ş.Urfa farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R^2

Şekil 33'de Şanlıurfa ili için eğitim ve test sonuçları beraber verilmiş olup en yüksek değer işaretlenmiştir.




Şekil 33 G. Antep farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R^2

Şekil 34'de Gaziantep ili için eğitim ve test sonuçları beraber verilmiş olup en yüksek değer işaretlenmiştir.




Şekil 34 Batman farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R^2

Şekil 35'de Batman ili için eğitim ve test sonuçları beraber verilmiş olup en yüksek değer işaretlenmiştir.



Şekil 35 Mardin farklı metotlar TBA uygulayarak /TBA uygulanmaksızın elde edilen eğitim/test R^2

Şekil 36’de Mardin ili için eğitim ve test sonuçları beraber verilmiş olup en yüksek değer işaretlenmiştir.



Şekil 36 Solar irradiation giriş verilerinin TBA analizi

Şekil 37’de belirtilen bileşenler; Güneş ışıınımı (PC1), Sıcaklık (PC2), Nem (PC3) ve Rüzgâr hızı (PC4) olarak isimlendirilmektedir. Bu bileşenler incelendiğine PC1 bileşeninin güneş ışıınımı tahmininin yapılmasında en etkili bileşen olduğunu görülmektedir. Daha sonra ise PC2 bileşeni gelmektedir. En düşük etkiye sahip olanlar PC3 (Nem) ve PC4 (rüzgâr hızı)’dır. Şekil 37’de anlaşıldığı üzere tahmin yapılırken sadece güneş ışıınımını(PC1) bile kullanmak doğru bir tahmin yapma açısından yeterli bir bilgi sağlamaktadır. Diğer bileşenler; sıcaklık, nem, rüzgâr hızı bunların etkisi düşük olduğundan doğru tahmin için etkileri azdır.

5 SONUÇLAR VE ÖNERİLER

Bu çalışma kapsamında; Diyarbakır, Şanlıurfa, Gaziantep, Batman ve Mardin illerinin güneş enerjisi potansiyelini belirlemek için Meteoroloji genel müdürlüğünden saatlik, güneşlenme süreleri ve günlük toplam global güneş ışıınımı verileri alınarak on farklı yöntem ile hangi yöntemin her bir İl'e ne kadar uyumlu olduğu incelenmiş ayrıca araştırılan bu iller için ışıınım sürelerine göre en yakın modeli bulmak için farklı metotlar geliştirilmiştir. Kaynakların verimli kullanılması gelişmekte olan ülkeler için çok önem arz etmektedir, bundan dolayı kaynakların verimli kullanılması adına farklı güçlüklerle elde edilen ölçümler kullanılarak bölge uygunluk analizlerinin yapılması çok önem kazanmaktadır. Beş il için 10 farklı yöntem kullanılmıştır. Bu yöntemler; Lasso, Lineer, Bayesian Ridge, SVM Lineer, RandomForest, Bagging, Ridge, Hubber, SVM RBF ve Adaboost yöntemleridir. Aynı yöntemlere TBA uygulanarak yöntemlerin sonuçları gözlemlenmiştir.

TBA uygulandığında sonuçlarda belirgin iyileşme sağlanmıştır. Lineer regresyon yöntemi TBA uygulanmaksızın elde edilen sonuçlar incelendiğinde tüm iller için en uygun yöntem olduğu görülmüştür. TBA uygulanarak elde edilen sonuçlar açısından ise beş il içinde Lineer SVM en uygun yöntem olarak tespit edilmiştir. Veriler dört temel bileşen üzerinden değerlendirilmiştir, güneş ışıınım süreleri, sıcaklık, nem ve rüzgâr hızı. TBA özellik çıkarımı sağlayarak verimliliği artırmakla kalmamış aynı zaman da hangi parametrelerin tahmin de önemli olduğunu da göstermiştir. TBA analizinde, güneş ışıınım süresinin %83 ile tahmin yöntemleri açısından en önemli parametre olduğu görülmüştür. TBA aynı zamanda nem ve rüzgâr hızının güneş ışıınım tahminin de etkisinin az olduğunu da göstermektedir. Sırasıyla nem için TBA % 4, rüzgâr hızı için TBA %2'dir. Her ilin kendi coğrafik şartları içerisinde değerlendirilmesi gerektiğini ve yöntemlerin farklı iller için farklı sonuçlar verdiğini yapılan çalışma bize göstermiştir.

Bu çalışmada güneş ışıınımı tahmin yöntemleri için makine öğrenmesi metotları kullanılmıştır. Bu metotlardan yapay sinir ağları(ysa) geri yayılım algoritması ile öğrenme yaptığından öğrenme süreçleri çok yavaş olmaktadır. YSA' nın bu

dezavantajına karşı olasılıksal sinir ağıları(osa) kullanılmıştır. OSA'lar, ysa'ya göre daha hızlı bir öğrenme sürecine sahiptirler. Bunlar küçük veri setlerinde iyi sonuç verirken, büyük veri setlerinde yeterince iyi sonuç vermemektedirler. Bu ikisine karşın destek vektör mekanizması(dvm) kullanılmıştır fakat dvm'de ikinci dereceden programlamadan ötürü aşırı bir hesaplama problemi yaşanmaktadır. İleri çalışmalarda yukarıda bahsedilen yavaş öğrenme, büyük veri setlerinde iyi sonuç vermeme, yüksek hesaplama karmaşası gibi sorunlara karşı daha iyi sonuç verecek makine öğrenme teknikleri üzerinde yoğunlaşılacaktır. Diğer taraftan bu çalışmada veriler gürültüsüz kabul edilmiştir, fakat gerçek hayatta ölçüm hataları, sensör hassasiyeti gibi nedenlerden ötürü sinyaller gürültü içermektedir. İleriki çalışmalarda aynı zamanda gürültü ölçüm durumlarında da iyi sonuçlar verebilecek makine öğrenmeleri üzerinde yoğunlaşılacaktır.

KAYNAKLAR

- [1]. Balat, M. 2010. Present situation and potential role of renewable energy in Turkey, Renewable Energy, (46): 1-13
- [2]. Karadağ, Ç., Gülsaç, I.I., Ersöz, A. ve Çalışkan, M. 2009. Çevre Dostu ve Temiz: Yenilenebilir Enerji Kaynakları, TUBİTAK Bilim ve Teknik, (498), 24-27.
- [3]. KIRBAŞ, İbrahim; ÇİFCİ, Ahmet; İŞYARLAR, Barış. Burdur İli Güneşlenme Oranı ve Güneş Enerjisi Potansiyeli. Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2013, 4.2: 20-23.
- [4]. DUFFIE, John A.; BECKMAN, William A. Solar engineering of thermal processes. John Wiley & Sons, 2013.
- [5]. BOZTEPE, Mutlu. Fotovoltaik Güç Sistemlerinde Verimliliği Etkileyen Parametreler. IV. İzmir Enerji Verimliliği Günleri, 2017, 19-20.
- [6]. <https://www.enerjibes.com/piranometre-nedir-ne-ise-yarar/>
- [7]. <https://www.mgm.gov.tr/genel/meteorolojikuydular.aspx>
- [8]. ADIYAMAN, Çetin. Türkiye'nin Yenilenebilir Enerji Politikaları. 2012. Master's Thesis. Niğde Üniversitesi.
- [9]. YILMAZ, Mutlu. Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. Ankara Üniversitesi Çevre Bilimleri Dergisi, 2012, 4.2: 33-54.
- [10]. KOÇ, Erdem; ŞENEL, Mahmut Can. Dünyada ve Türkiye'de enerji durumu-genel değerlendirme. Mühendis ve Makina, 2013, 54.639: 32-44.
- [11]. VARINCA, Kamil B.; GÖNÜLLÜ, M. Talha. Türkiye'de güneş enerjisi potansiyeli ve bu potansiyelin kullanım derecesi, yöntemi ve yaygınlığı üzerine bir araştırma. I. Ulusal Güneş ve Hidrojen Enerjisi Kongresi, 2006, s 272: 275
- [12]. <http://www.yegm.gov.tr/MyCalculator/Default.aspx>

- [13]. ANGSTROM, Anders. Solar and terrestrial radiation. Report to the international commission for solar research on actinometric investigations of solar and atmospheric radiation. Quarterly Journal of the Royal Meteorological Society, 1924, 50.210: 121-126.
- [14]. ÖGELMAN, H.; ECEVIT, A.; TASDEMIROĞLU, E. A new method for estimating solar radiation from bright sunshine data. Solar Energy, 1984, 33.6: 619-625.
- [15]. GLOVER, J.; MCCULLOCH, J. S. G. The empirical relation between solar radiation and hours of sunshine. Quarterly Journal of the Royal Meteorological Society, 1958, 84.360: 172-175.
- [16]. BARBARO, S., et al. Diffuse solar radiation statistics for Italy. Solar Energy, 1981, 26.5: 429-435.
- [17]. KILIÇ, Abdurrahman; ÖZTÜRK, Aksel. Güneş enerjisi. Kipaş Dağıtımçılık, 1983.
- [18]. BENSON, R. B., et al. Estimation of daily and monthly direct, diffuse and global solar radiation from sunshine duration measurements. Solar energy, 1984, 32.4: 523-535.
- [19]. GOPINATHAN, K. K. A simple method for predicting global solar radiation on a horizontal surface. Solar & wind technology, 1988, 5.5: 581-583.
- [20]. NEWLAND, F. J. A study of solar radiation models for the coastal region of South China. Solar Energy, 1989, 43.4: 227-235.
- [21]. FAKIOGLU, T.; ECEVIT, A. A procedure to obtain the average daily total and the hourly values of solar radiation for Turkey. TR Journal of Physics, 1995, 19: 681-8.
- [22]. SAMUEL, T. D. M. A. Estimation of global radiation for Sri Lanka. Solar Energy (Journal of Solar Energy Science and Engineering);(United States), 1991, 47.5.
- [23]. AKSOY, Bülent. Estimated monthly average global radiation for Turkey and its comparison with observations. Renewable Energy, 1997, 10.4: 625-633.
- [24]. ELAGIB, Nadir Ahmed; MANSELL, Martin G. New approaches for estimating global solar radiation across Sudan. Energy Conversion and Management, 2000, 41.5: 419-434.
- [25]. BAKIRCI, Kadir. Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey. Energy, 2009, 34.4: 485-501.
- [26]. ULGEN, Koray; HEPBASLI, Arif. Solar radiation models. Part 2: Comparison and developing new models. Energy Sources, 2004, 26.5: 521-530.

- [27]. TARHAN, Sefa; SARI, Ahmet. Model selection for global and diffuse radiation over the Central Black Sea (CBS) region of Turkey. *Energy Conversion and Management*, 2005, 46.4: 605-613.
- [28]. LOUCHE, A., et al. Correlations for direct normal and global horizontal irradiation on a French Mediterranean site. *Solar Energy*, 1991, 46.4: 261-266.
- [29]. KALLIOĞLU, Mehmet Ali. Niğde İli İçin Yatay Düzenleme Gelen Günlük Tüm, Yayılı Ve Direkt Güneş Işınımını Hesaplama Modeli Geliştirilmesi. 2014. PhD Thesis. Niğde Üniversitesi.
- [30]. QUEJ, Victor H., et al. ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2017, 155: 62-70.
- [31]. CHITEKA, K.; ENWEREMADU, C. C. Prediction of global horizontal solar irradiance in Zimbabwe using artificial neural networks. *Journal of Cleaner Production*, 2016, 135: 701-711.
- [32]. RAO, KDV Siva Krishna; RANI, B. Indu; ILANGO, G. Saravana. Estimation of daily global solar radiation using temperature, relative humidity and seasons with ANN for Indian stations. In: 2012 International Conference on Power, Signals, Controls and Computation. IEEE, 2012. p. 1-6.
- [33]. WANG, Zhe; WANG, Fei; SU, Shi. Solar irradiance short-term prediction model based on BP neural network. *Energy Procedia*, 2011, 12: 488-494.
- [34]. ANGELA, Karoro; TADDEO, Ssenyonga; JAMES, Mubiru. Predicting global solar radiation using an artificial neural network single-parameter model. *Advances in Artificial Neural Systems*, 2011, 2011: 16.
- [35]. MELLIT, Adel; PAVAN, Alessandro Massi. A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*, 2010, 84.5: 807-821.
- [36]. RIVINGTON, Mike, et al. Evaluation of three model estimations of solar radiation at 24 UK stations. *Agricultural and Forest Meteorology*, 2005, 132.3-4: 228-243.
- [37]. ŞEN, Zekai. Fuzzy algorithm for estimation of solar irradiation from sunshine duration. *Solar Energy*, 1998, 63.1: 39-49.
- [38]. ŞEN, Zekai; TAN, Elçin. Simple models of solar radiation data for northwestern part of Turkey. *Energy Conversion and Management*, 2001, 42.5: 587-598.
- [39]. WONG, L. T.; CHOW, W. K. Solar radiation model. *Applied Energy*, 2001, 69.3: 191-224.
- [40]. DORVLO, Atsu SS; JERVASE, Joseph A.; AL-LAWATI, Ali. Solar radiation estimation using artificial neural networks. *Applied Energy*, 2002, 71.4: 307-319.

- [41]. SFETSOS, A.; COONICK, A. H. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Solar Energy*, 2000, 68.2: 169-178.
- [42]. SÖZEN, Adnan; ARCAKLIOĞLU, Erol; ÖZALP, Mehmet. Estimation of solar potential in Turkey by artificial neural networks using meteorological and geographical data. *Energy Conversion and Management*, 2004, 45.18-19: 3033-3052.
- [43]. HERRERA, Francisco; LOZANO, Manuel; VERDEGAY, Jose L. Tuning fuzzy logic controllers by genetic algorithms. *International Journal of Approximate Reasoning*, 1995, 12.3-4: 299-315.
- [44]. MICHAEL, A.; TAKAGI, Hideyuki. Integrating design stages of fuzzy systems using genetic algorithms. In: *Proceedings of the 2nd IEEE International Conference on Fuzzy Systems. FUZZ-IEEE*. 1993. p. 612-7.
- [45]. BELARBI, Khaled; TITEL, Faouzi. Genetic algorithm for the design of a class of fuzzy controllers: an alternative approach. *IEEE Transactions on fuzzy systems*, 2000, 8.4: 398-405.
- [46]. PARK, Young Jun; CHO, Hyung Suck; CHA, Dong Hyuk. Genetic algorithm-based optimization of fuzzy logic controller using characteristic parameters. In: *Proceedings of 1995 IEEE International Conference on Evolutionary Computation*. IEEE, 1995. p. 831-836.
- [47]. CHEONG, France; LAI, Richard. Constraining the optimization of a fuzzy logic controller using an enhanced genetic algorithm. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2000, 30.1: 31-46.
- [48]. ANGSTROM, Anders. Solar and terrestrial radiation. Report to the international commission for solar research on actinometric investigations of solar and atmospheric radiation. *Quarterly Journal of the Royal Meteorological Society*, 1924, 50.210: 121-126.
- [49]. PRESCOTT, J. A. Evaporation from a water surface in relation to solar radiation. *Trans. Roy. Soc. S. Aust.*, 1940, 46: 114-118.
- [50]. BAKIRCI, Kadir. Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey. *Energy*, 2009, 34.4: 485-501.
- [51]. ARAS, Haydar; BALLI, Ozgur; HEPBASLI, Arif. Global solar radiation potential, part 1: model development. *Energy Sources*, 2006, 1.3: 303-315.
- [52]. ÖZÇALIK, H. R.; KÜÇÜKTÜFEKÇİ, Ahmet. Dinamik Sistemlerin Yapay Sinir Ağları ile Düz ve Ters Modellenmesi. *KSÜ Fen ve Mühendislik Dergisi*, 2003, 6.1: 26-35.

- [53]. KALOGIROU, Soteris A.; BOJIC, Milorad. Artificial neural networks for the prediction of the energy consumption of a passive solar building. *Energy*, 2000, 25.5: 479-491.
- [54]. LAURET, Philippe, et al. A benchmarking of machine learning techniques for solar radiation forecasting in an insular context. *Solar Energy*, 2015, 112: 446-457.
- [55]. VOYANT, Cyril, et al. Multi-horizon solar radiation forecasting for Mediterranean locations using time series models. *Renewable and Sustainable Energy Reviews*, 2013, 28: 44-52.
- [56]. CHAABENE, Maher; AMMAR, Mohsen Ben. Neuro-fuzzy dynamic model with Kalman filter to forecast irradiance and temperature for solar energy systems. *Renewable Energy*, 2008, 33.7: 1435-1443.
- [57]. BURGESS, Christopher JC. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 1998, 2.2: 121-167.
- [58] KÖKNAROĞLU, Hayati; ACITAŞ, Şükrü; ŞENOĞLU, Birdal. Evaluating of beef cattle performance and profitability using robust regression analysis. *Harran Tarım ve Gıda Bilimleri Dergisi*, 23.3: 277-286.
- [59]. TOPAL, Mehmet, et al. Çoklu doğrusal bağlantı durumunda ridge ve temel bileşenler regresyon analiz yöntemlerinin kullanımı. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 2010, 41.1: 53-57.
- [60]. ŞAMKAR, HATİCE; ALPU, ÖZLEM; ALTAN, EKREM. RİDGE REGRESYONDA M TAHMİN EDİCİLERİNİN KULLANIMI ÜZERİNE BİR UYGULAMA. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 2011, 26.1.
- [61]. AKMAN, M. Veri madenciliğine genel bakış ve random forests yönteminin incelenmesi: sağlık alanında bir uygulama. 2010. PhD Thesis. Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara.
- [62]. CUTLER, Adele; CUTLER, D. Richard; STEVENS, John R. Random forests. In: *Ensemble machine learning*. Springer, Boston, MA, 2012. p. 157-175.
- [63]. CUTLER, Adele; CUTLER, D. Richard; STEVENS, John R. Tree-based methods. In: *High-Dimensional Data Analysis in Cancer Research*. Springer, New York, NY, 2009. p. 1-19.
- [64]. BREIMAN, Leo. Random forests. *Machine learning*, 2001, 45.1: 5-32.
- [65]. YILMAZ IŞIKHAN, Selen. Mikrodizilim Gen İfade Çalışmalarında Genelleştirme Yöntemlerinin Regresyon Modelleri Üzerine Etkisi. 2014.

- [66]. DENİZ, Emrah; KEMAL, A. T. İ. K. Güneş Işınım Şiddeti Tahminlerinde Yapay Sinir Ağları ve Regresyon Analiz Yöntemleri Kullanımının İncelenmesi. Isı bilimi ve tekniği dergisi, 2007, 27.2: 15-20.
- [67]. Z. Filiz, “Güvenilirlik Çözümlemesi, Temel Bileşenler ve Faktör Çözümlemesi”, Anadolu Üniversitesi Bilim ve Teknoloji Dergisi, Cilt.4, No.2, s. 211–222, 2003.[1]
- [68]. M. Çilli, “İnsan Hareketlerinin Modellenmesi ve Benzeşiminde Temel Bileşenler Analizi Yönteminin Kullanılması”, Doktora Tezi, Hacettepe Üniversitesi Sağlık Bilimleri Enstitüsü, 240 s, 2007.[2]
- [69]. <http://www.zafercomert.com/IcerikDetay.aspx?zcms=78>
- [70]. YILDIZ, Eray; SEVİM, Yusuf. Comparison of linear dimensionality reduction methods on classification methods. In: 2016 National conference on electrical, electronics and biomedical engineering (ELECO). IEEE, 2016. p. 161-164.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : YAHYA AKIL
Uyruğu : TC
Doğum Yeri ve Tarihi : BATMAN-10.09.1984
Telefon : (555) 255 2205
Faks :
e-mail : yahyaakil@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Batman Anadolu Lisesi	2004
Üniversite	: Yıldız Teknik Üniversitesi	2009
Yüksek Lisans	: Batman Üniversitesi	Devam
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2015-Devam	Nokia	RF Opt.Takım Lideri
2011-2015	Avea	RF Optimizasyon

UZMANLIK ALANI

Network Expert

YABANCI DİLLER

İngilizce