



T.C.

**BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI**

Yüksek Lisans Tezi

**YAPAY SİNİR AĞLARI VE MAKİNE ÖĞRENMESİ
İLE GÜNEŞ IŞINIMININ ANALİZİ: BURSA VE
ÇANAKKALE ÖRNEĞİ**

**Ebru KORKMAZ
185010009**

Tez Danışmanı:

Doç. Dr. Necla TEKTAŞ

Bandırma 2022

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI

Yüksek Lisans Tezi

**YAPAY SİNİR AĞLARI VE MAKİNE ÖĞRENMESİ
İLE GÜNEŞ IŞINIMININ ANALİZİ: BURSA VE
ÇANAKKALE ÖRNEĞİ**

Ebru KORKMAZ
185010009

Tez Danışmanı

Doç. Dr. Necla TEKTAŞ

Bandırma 2022

ETİK BEYAN SAYFASI

TÜRKİYE CUMHURİYETİ
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Bu belge ile, bu tezdeki bütün bilgilerin akademik kurallara ve etik ilkelere uygun olarak toplanıp sunulduğunu beyan ederim. Bu kural ve ilkelerin gereği olarak, çalışmada bana ait olmayan tüm veri, düşünce ve sonuçları andığımı ve kaynağını gösterdiğimi ayrıca beyan ederim. (12/01/2022)

Ebru KORKMAZ

ÖZET

YAPAY SİNİR AĞLARI VE MAKİNE ÖĞRENMESİ İLE GÜNEŞ IŞINIMININ ANALİZİ: BURSA VE ÇANAKKALE ÖRNEĞİ

Ebru KORKMAZ

Güneş enerjisi dünya üzerinde en önemli ve en çok bulunan yenilenebilir enerji kaynağıdır. Doğada enerji kaynaklarının az oluşu, çevreye verdiği zarar ve tükenecek olması nedeniyle yenilenebilir enerji kaynaklarıyla ilgili çalışmaların artmasına neden olmuştur. Yapılan bu çalışmada da yenilenebilir enerji kaynaklarından olan güneş enerjisi üzerine yapılmıştır.

Çalışmada Bursa ve Çanakkale illerine ait 2015-2019 yılları arasındaki günlük/saatlik güneş ışıınım verileri kullanılarak Yapay Sinir Ağları ile tahminleme. Makine Öğrenmesi Algoritması ile sınıflama analizi yapılmıştır. Analiz sonuçları karşılaştırıldığında Bursa ilinin sonuçlarında Bayesian yöntemi en iyi sonucu vermişken. Çanakkale ili için en iyi sonucu Levenberg-Marquardt yöntemi vermiştir. Makine öğrenmesi algoritmasında ise sınıflama analizi yapılmış olup dört temel algoritma kullanılmıştır. Kullanılan algoritmalarda en iyi sonuca ise Decision Tree (Karar Ağaçları) yöntemiyle Bursa ilinin verileri ile ulaşılmıştır. Bu doğrultuda öneriler ve yorumlar yapılmıştır.

Anahtar Sözcükler: Güneş Işınımı, Yapay Sinir Ağları, Makine Öğrenmesi, Tahminleme Teknikleri

ABSTRACT

ANALYSIS OF SOLAR RADIATION WITH ARTIFICIAL NEURAL NETWORKS AND MACHINE LEARNING: EXAMPLE OF BURSA AND ÇANAKKALE

Ebru KORKMAZ

Solar energy is the most important and most abundant renewable energy source in the world. The scarcity of natural energy resources. Due to the damage it causes to the environment and the fact that it will be exhausted, it has led to an increase in studies on renewable energy sources.

In this study, solar energy, which is one of the renewable energy sources, was also carried out. When the analysis results are compared, the Bayesian method gave the best results in the results of Bursa province, while the Levenberg-Marquardt method gave the best result for Çanakkale. In the machine learning algorithm, classification analysis was made and four basic algorithms were used. The best result in the algorithms used was obtained with the data of Bursa province with the Decision Tree method. In this direction, suggestions and comments were made.

Keywords: Solar Radiation, Artificial Neural Networks, Machine Learning, Prediction Techniques

ÖNSÖZ

Tez çalışmamın gerek konu seçiminde gerekse tezimin şekillenmesinde bana yol gösteren araştırmamın her adımında değerli zamanını ve engin bilgileriyle bana her türlü desteği sağlayan saygıdeğer ve çok kıymetli danışman hocam Sayın Doç. Dr. Necla TEKTAŞ 'a saygı ve sonsuz teşekkürlerimi sunarım.

Tez çalışmamda engin bilgileri ve uzman görüşleri ile bana her konuda destek ve emek veren saygıdeğer ve çok kıymetli Bandırma Onyedi Eylül Üniversitesinde Akıllı Ulaşım Sistemleri Bölüm Başkanı Sayın Prof. Dr. Mehmet TEKTAŞ 'a saygı ve sonsuz teşekkürlerimi sunarım. Ayrıca engin bilgileri ve uzman görüşleri ile bana her konuda destek ve emek veren Bandırma Onyedi Eylül Üniversitesinde Mühendislik ve Doğa Bilimleri Fakültesinde akademik görevini devam ettiren Sayın Dr. Öğr. Üyesi Abdullah Elen'e, Çanakkale Onsekiz Mart Üniversitesinde akademik görevini devam ettiren Sayın Öğr.Gör. Recep Yavuz TURAN'a ve Öğr.Gör. Sevcan TURAN'a teşekkürü borç bilirim.

Ayrıca lisans ve yüksek lisans eğitimlerim boyunca her türlü desteği ve doğru yolu gösteren başta Bandırma Onyedi Eylül Üniversitesi Ekonometri Bölüm Başkanı Sayın Prof.Dr. Metehan YILGÖR 'e ve tüm hocalarıma teşekkürlerimi sunarım.

Tez çalışmamın ilerlemesinde gerek uykusuz kalarak gerekse bana motivasyon kaynağı olan gece gündüz demeden hiç sıkılmadan her anımda yanımda olan canım arkadaşım Sevin KARAGÖZ'e sonsuz teşekkürlerimi sunarım.

Son olarak benim her daim arkamda olan ve her kararına saygı duyan benim bu konuma gelmemde maddi manevi bütün desteğini esirgemeyen canım aileme sonsuz teşekkürlerimi sunarım.

Ebru KORKMAZ

Bandırma/BALIKESİR

12/01/2022

İÇİNDEKİLER

İçindekiler

ETİK BEYAN SAYFASI.....	i
ÖZET	ii
ABSTRACT	iii
ÖNSÖZ.....	iv
İÇİNDEKİLER.....	v
TABLolar.....	viii
ŞEKİLLER.....	x
KISALTMALAR	xii
GİRİŞ	13
BİRİNCİ BÖLÜM	16
1.1. ENERJİ KAYNAKLARI	16
1.2. YENİLENEBİLİR ENERJİ KAYNAKLARI	18
1.2.1. Hidrolik Enerji	18
1.2.2. Dalga Gel-Git Enerji	18
1.2.3. Jeotermal Enerji	19
1.2.4. Biyokütle Enerji	19
1.2.5. Hidrojen Enerji.....	19
1.2.6. Rüzgar Enerjisi.....	19
1.2.7. Güneş Enerjisi	20
1.2.7.1. Güneş Enerjisi ile İlgili Temel Kavramlar	22
1.2.7.2. Güneş Enerjisinin Tarihi Gelişimi	25
1.2.7.3. Dünya'daki Güneş Enerjisi	27
1.2.7.3.1. En Çok Güneş Alan Bölge ve Ülkeler	27
1.2.7.3.2. Dünyada Güneş Enerjisi Üretiminde Öne Çıkan Ülkeler	28
1.2.7.4. Türkiye'de Güneş Enerjisi	29
1.3. İLGİLİ ÇALIŞMALAR	31
İKİNCİ BÖLÜM.....	45
2.1.1. Yapay Zeka	45
2.1.1.1. Yapay Zekanın Tarihçesi	46
2.1.1.2. Yapay Zekanın Kullanım Alanları	48

2.1.2. Yapay Sinir Ağı (YSA) Teknikleri	49
2.1.2.1. Yapay Sinir Ağının Yapısı	51
2.1.2.1.1. Tek Katmanlı Yapay Sinir Ağları	53
2.1.2.1.2. Çok Katmanlı Yapay Sinir Ağları.....	53
2.1.2.1.2.1. İleri Beslemeli (Feed Forward) Yapay Sinir Ağı.....	53
2.1.2.1.2.2. Geri Beslemeli (Feedback) Yapay Sinir Ağı	54
2.1.2.1.2.3. Levenberg-Marquardt Algoritması	55
2.1.2.1.2.4. Bayesian Yöntemi	56
2.2. MAKİNE ÖĞRENMESİ.....	58
2.2.1. Makine Öğrenmesi Yöntemleri.....	60
2.2.1.1. Danışmanlı Öğrenme (Supervised Learning).....	60
2.2.1.2. Danışmansız Öğrenme (Unsupervised Learning)	60
2.2.1.3. Yarı Danışmanlı Öğrenme(Semi-Supervised Learning).....	60
2.2.1.4. Takviyeli Öğrenme (Reinforcement Learning).....	61
2.2.1.5. Yoğun Öğrenme (Intensive Learning)	61
2.2.2. Makine Öğrenmesi Terminolojisi	61
2.2.2.1. Model Oluşturma	61
2.2.2.2. Özellik (Feature) Çıkarımı	61
2.2.2.3. Hedef (Target).....	62
2.2.2.4. Eğitim (Training)	62
2.2.2.5. Tahmin (Prediction)	62
2.2.3. Makine Öğrenmesinin Ölçekleri	62
2.2.3.1. Accuracy (Doğruluk)	62
2.2.3.2. Sensitivity (Duyarlılık).....	63
2.2.3.3. Specificity (Belirginlik)	64
2.2.3.4. Precision (Hassaslık).....	64
2.2.3.5. F-Skor(Score)	64
2.2.4. Makine Öğrenmesinde Sınıflandırma	65
2.2.4.1. En Yakın K Komşu Algoritması (K- Nearest Neighbor).....	65
2.2.4.2. Naive Bayes (NB) Sınıflandırıcısı	66
2.2.4.3. Decision Tree (Karar Ağacı).....	67
2.2.4.4. Standardized Variable Distances (SVD).....	68
2.2.5. Makine Öğrenmesi Doğrulama Yöntemleri.....	69

2.2.5.1. Çapraz Doğrulama Yöntemi	69
2.2.5.1.1. K-Parçalı Çapraz Doğrulama	70
2.2.5.1.2. Birisi Dışarıda Çapraz Doğrulama Yöntemi	70
ÜÇÜNCÜ BÖLÜM	71
3.1. GÜNEŞ IŞINIMININ YAPAY SİNİR AĞLARI VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ANALİZİ	71
3.1.1. MATLAB Yapay Sinir Ağları Tasarımcısı	71
3.2. BULGULAR	81
3.2.1. Verinin Elde Edilmesi	81
3.2.2. Verilerin Düzenlenmesi	81
3.2.3. Yapay Sinir Ağların Analiz Sonuçları	81
3.3. MAKİNE ÖĞRENMESİ ANALİZ SONUÇLARI	91
SONUÇ	103
KAYNAKÇA	106

TABLÖLAR

Tablo 1: En Çok Güneş Enerjisini Alan Ülkelerin Dağılımı	28
Tablo 2: Yapay Zeka Kronolojik Sıralaması	47
Tablo 3: YSA’da Bazı Toplama Fonksiyonlar.....	52
Tablo 4: Çanakkale ve Bursa Hata Değerlerinin Karşılaştırması	91
Tablo 5: Güneş Radyasyonunun Sınıf Etiketlerine Ayırıştırılması.....	91
Tablo 6: Bursa ve Çanakkale Makine Öğrenmesi Algoritmasının Karşılaştırması	92
Tablo 7: $0 \leq y < 0.1$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	92
Tablo 8: $0.1 \leq y < 0.2$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	93
Tablo 9: $0.2 \leq y < 0.3$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	93
Tablo 10: $0.3 \leq y < 0.4$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	94
Tablo 11: $0.4 \leq y < 0.5$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	94
Tablo 12: $0.5 \leq y < 0.6$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	95
Tablo 13: $0.6 \leq y < 0.7$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	95
Tablo 14: $0.7 \leq y < 0.8$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	96
Tablo 15: $0.8 \leq y < 0.9$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	96
Tablo 16: $0.9 \leq y < 1.0$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması	97
Tablo 17: $0 \leq y < 0.1$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	97
Tablo 18: $0.1 \leq y < 0.2$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	98
Tablo 19: $0.2 \leq y < 0.3$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin	

Karşılaştırılması	98
Tablo 20: $0.3 \leq y < 0.4$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	99
Tablo 21: $0.4 \leq y < 0.5$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	99
Tablo 22: $0.5 \leq y < 0.6$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	100
Tablo 23: $0.6 \leq y < 0.7$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	100
Tablo 24: $0.7 \leq y < 0.8$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	101
Tablo 25: $0.8 \leq y < 0.9$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	101
Tablo 26: $0.9 \leq y < 1.0$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması	102

ŞEKİLLER

Şekil 1 : Enerji Kaynaklarının Sınıflandırılması	16
Şekil 2 : Güneş Sistemi.....	21
Şekil 3 : Güneş Enerjisinin Tarihi Gelişimi.....	26
Şekil 4 : Dünya Güneş Enerjisi Haritası	27
Şekil 5 : Türkiye Güneş Enerjisi Haritası	30
Şekil 6 : Türkiye Elektrik Enerjisinin Kullanım Oranı.....	31
Şekil 7 : Yapay Zekâ Tanımı	45
Şekil 8 : YSA'nın Kullanım Alanları	49
Şekil 9 : Yapay Sinir Ağının Yapısı (Nöron)	50
Şekil 10: Temel YSA Hücresinin Matematiksel Gösterimi	51
Şekil 11: Tek Katmanlı YSA Modeli	53
Şekil 12: Yapay Sinir Ağlarının Yapısı (İBYSA)	54
Şekil 13: Geri Beslemeli YSA Modeli	55
Şekil 14: Doğruluk Ölçütü.....	63
Şekil 15: MATLAB Ana Ekran.....	71
Şekil 16: Yapay Sinir Ağları Tasarımcısının Açılması	72
Şekil 17: Analiz Komutu	72
Şekil 18: Neural Network Start(nnstart) – Yapay Sinir Ağlarının Başlatılması	73
Şekil 19: Neural Time Series(ntstool)- Sinirsel Zaman Serileri (ntstool)	74
Şekil 20: Hedef Veri ve Zaman Serisi Formatının Belirlenmesi	75
Şekil 21: Eğitim, Doğrulama ve Test Yüzdeliklerinin Belirlenmesi.....	76
Şekil 22: Network Architecture- Ağ Mimarisi	76
Şekil 23: Train Network – Eğitim Ağı	77
Şekil 24: Evaluate Network- Ağı Değerlendirilmesi.....	78
Şekil 25: Deploy Solution – Çözüm Dağıtımı.....	78
Şekil 26: Save Results- Sonuçların Kaydedilmesi.....	79
Şekil 27: Komut Dosyası	79

GRAFİKLER

Grafik 1 : Bursa Eğitim. Doğrulama ve Test Kümelerine İlişkin Hata Performansları	83
Grafik 2: Çanakkale Eğitim. Doğrulama ve Test Kümelerine İlişkin Hata Performansları	83
Grafik 3: Bursa Eğitim Grafiği	84
Grafik 4: Çanakkale Eğitim Grafiği	85
Grafik 5: Bursa Hata Korelasyon	86
Grafik 6: Çanakkale Hata Korelasyon.....	86
Grafik 7: Bursa İlinin Hata Histogram	87
Grafik 8: Çanakkale İlinin Hata Histogram	88
Grafik 9: Bursa İlinin Zaman Serisi 1 İçin Çıkış Elemanı 1 Yanıtı	88
Grafik 10: Çanakkale İlinin Zaman Serisi 1 İçin Çıkış Elemanı 1 Yanıtı	89
Grafik 11: Bursa İlinin Eğitim Regresyonu	90
Grafik 12: Çanakkale İlinin Eğitim Regresyonu.....	90

KISALTMALAR

YSA : Yapay Sinir Ağları

D-YSA : Dalgacık Yapay Sinir Ağları

GA : Genetik Algoritma

ANFIS : Adaptive Neuro Fuzzy Inference System (Adaptif Sinirsel Bulanık Çıkarım Sistemi)

NAR : Doğrusal Olmayan Otoregresif Model

ARIMA: Otoregresif Hareketli Ortalama Model

SO₂ : Kükürt dioksit

CO : Karbondioksit

PM : Partikül Madde

NO₂ : Azot dioksit

KNN : K-Nearest Neighbor (EN Yakın Komşu Algoritması)

RNN : Recurrent Neural Network (Basit Sinir Ağı Mimarisi)

MGM : Meteoroloji Genel Müdürlüğü

GW : Gigawatt

MW : Miliwatt

BM : Bulanık Mantık

ÇLR : Çoklu Linear Regresyon

MAPE : Ortalama Mutlak Yüzde Hata

MAE : Ortalama Mutlak Hata

RMSE : Kök Ortalama Kare Hata

MSE : Ortalama Kare Hata

GİRİŞ

İnsanoğlu yaradılışından günümüze kadar birçok enerji kaynağını kendi yararına kullanmış ve ilk yıllarda besin yoluyla enerji ihtiyaçlarını karşılasalar da gün geçtikçe ihtiyaçlar artıkça besin yoluyla alınan enerji ihtiyaçlarını karşılayamamışlardır(Yıldız, 2017). Dünyadaki sanayileşme hareketlerinin başlaması ve özellikle de üretim sırasında kullanılan fosil kaynaklı enerji talebi artmıştır. Ancak enerji ihtiyacındaki artış, mevcut kaynakların yetersizliği sebebi ve doğaya verdiği zarar, sera gaz salınımları ülkeler için önemli tehditler oluşturmaktadır(Akar, 2016). Enerji talebinin giderilmesi ve aynı zamanda doğaya zarar verici bir etkinin olmaması için yenilenebilir enerji kaynaklarının kullanımı gereklilik arz etmektedir ve teşvik edilmelidir(Yıldırım, 2016).

Yenilenebilir sözcüğü doğadaki kaynaklardan elde edilebilen ve doğa tarafından daima üretilen anlamına gelmektedir. İnsanlığın varoluşuyla birlikte mevcudiyeti olan ancak zaman içerisinde gelişen teknoloji ile insanların üzerinde kullanım imkânlarının arttığı kaynaklar günümüz dünyasında insanlık için çok daha önemli hale gelmiştir(Kanat, 2019). Bu kapsamda da sürdürülebilir olması ve doğada sınırsız bulunmasından dolayı birçok alanda enerji bakımından rekabet eden yenilenebilir enerji kaynaklarına ilgi artmıştır. Yenilenebilir enerji kaynakları başlıca; güneş enerjisi, jeotermal enerji, rüzgar enerjisi, hidrojen enerjisi, hidrolik enerji, deniz kökenli enerjiler ve biyokütle enerji gibi enerji çeşitleri altında incelenmektedir(Önal ve Yarbay, 2010). Yenilenebilir enerji kaynakları güç üretimi, sıcak su sağlama ve mekân ısıtma, araç yakıtları ve kırsal faaliyetler gibi birçok alanda kullanılmaktadır. Yenilenebilir enerji güç üretim kapasitesinin yaklaşık %4'ünü oluşturmakta ve hidroelektrik enerjisi hariç dünya çapında elektrik üretiminin yaklaşık %3'ünü karşılamaktadır. Birçok yapının sıcak su ve mekân ısınması güneş, biyokütle ve jeotermal enerji ile sağlanmaktadır(Yılmaz, 2012).

Yenilenebilir enerji kaynakları ülkelerin enerji ihtiyaçlarını yerli doğal kaynaklarla karşılayarak dış ülkelere bağımlılıklarını en aza indirmesi, doğada bulunan yenilenebilir enerji kaynakları çeşitlendirerek sürdürülebilir enerji kullanımının sağlanması ve enerji tüketimi sonucunda doğaya verilen zararların azaltılması açısından son derece önemlidir. Türkiye'nin bünyesinde bulunan yenilenebilir enerji potansiyelini verimli ve daha etkin bir şekilde kullanması adına özellikle son zamanlarda yaşanan olumlu gelişmeler, öngörülen hedeflerin gerçekleştirilmesi kapsamında katkı

sağlamaktadır(İnan, Akbulut, & Aslan, 2018). Türkiye yenilenebilir enerji kaynakları bakımından oldukça zengin bir ülkedir. Bulunduğu coğrafi konumundan dolayı elverişli iklim koşulları sürdürülebilir ve yenilenebilir enerji kaynaklarına yatırım yapılmasını kolaylaştırmaktadır(Ervural, 2018).

Güneş enerjisi, yenilenebilir ve temiz kaynaklara olan ihtiyacın her geçen gün artması ve sürdürülebilir nitelikteki enerjiler arasında yer alması nedeniyle ön sıralarda gelmektedir. Güneş enerjisinin elektrik üretimine katkısı da gün geçtikçe artmaktadır. Türkiye'nin coğrafi konumundan dolayı güneş enerjisiyle ilgili yapılan çalışmaların, devlet yatırımlarının gelecekte de daha çok artması beklenmektedir. Güneş enerjisi. Güneş'in çekirdeğinde oluşan füzyon reaksiyonu ile açığa çıkan ışıma enerjisidir(Kaynar, 2020) . Doğa da sınırsız erişimi olan enerjiye dönüştürülmesi az maliyetli ve çevre dostu olarak da bilinen güneş enerjisinin her alanda kullanımı artmaktadır. Bu çalışma kapsamında. Çanakkale ve Bursa illerine ait 2015-2019 yılları arasındaki güneş ışıma verileri kullanılarak analiz edilmesinde yapay sinir ağları ile tahminleme, makine öğrenmesi algoritması ile de sınıflandırma yapılması amaçlanmıştır.

Çalışma üç bölümden oluşmaktadır. Birinci bölümde tezin genel yapısı ve aşamaları, giriş bölümünde enerji kaynakları ile ilgili bilgiler verilmiş olup enerji kaynakları altında yenilenebilir enerji kaynakları (hidrojen, dalga gel-git, jeotermal, biyokütle, rüzgar, güneş, hidrolik) açıklanacaktır. Güneş enerjisinin Dünya'da ve Türkiye'deki öneminden ve güneşin enerjiye dönüştürülmesi ele alınacaktır. Sonra; Güneş ışımasının yapay sinir ağları ve makine öğrenmesi ilgili daha önceki yapılan çalışmalardan çalışmamı destekleyen literatür (ilgili çalışmalar) iki temel başlık altında incelenecektir.

İkinci bölümde; araştırmanın önemini ortaya koyan ve literatüre önem kazandıran günümüzde de önemli bir yere sahip olan tahminleme tekniklerinden yapay zeka konusu açıklanacak arkasından yapay zekanın alt dallarından yapay sinir ağları ve makine öğrenmesi hakkında bilgiler verilecektir.

Son bölümde ise MATLAB Programı kullanılarak yapay sinir ağlarında yapılan tahminleme anlatılacak Çanakkale ve Bursa illerine ait 2015-2019 yılları arasındaki güneş ışıma verileri yapay sinir ağları ve makine öğrenmesi algoritmaları ile analiz edilecek, analiz edilen sonuçlar karşılaştırılıp yorumlanacaktır. Analiz sonuçları doğrultusunda güneş ışıma panellerine ve güneş ışıma olgusuna ait bilgiler verilecektir.

Günümüz yaşam koşullarının geliştiđi ve enerji kaynaklarının tüketildiđi göz ardı edilemeyecek bir gerçektir. Bu farkındalıkla birlikte insanođlu sürdürülebilir nitelikte yenilebilir enerji kaynakları arayışlarına girmektedir. Dünya’da ve Türkiye’de yenilenebilir enerji kaynakları alternatifleri olarak güneş enerjisi, biyokütle enerjisi, rüzgar enerjisi, fosil yakıt enerjisi ve nükleer enerji gibi daha birçok sayabileceğimiz tekrar yararlanabilecekleri enerji kaynakları olarak değeriendirilmektedir.




BİRİNCİ BÖLÜM

1.1. ENERJİ KAYNAKLARI

Enerji maddenin bir biçimidir ve madde enerjiye sahiptir. Günlük yaşamamızda “enerji” terimi denildiğinde çoğunlukla iş ve ısı enerjisi kastedilmektedir(Doğan, 2006)Isınma için ihtiyacımız olan ısı enerjisi genellikle çeşitli yakacakların yakılması sonucunda kimyasal enerjiden elde edilir. Teknolojinin ihtiyacı olan ısı enerjisinin temini de benzer şekildedir. Isı enerjisinden termodinamiğin ikinci kanununa göre ancak belirli bir verimle mekanik enerji elde edilebilir(Doğan, 2006).

Enerji kaynakları kullanılışlarına göre yenilenebilir ve yenilenemez enerji kaynakları olarak iki bölüme ayrılırken; dönüştürülme biçimlerine göre enerji kaynakları birincil ve ikincil enerji kaynakları olarak da ikiye ayrılmaktadır(Kaya et al., 2018)Şekil 1 ‘de gösterilmiştir.



Şekil 1. Enerji Kaynaklarının Sınıflandırılması

Yenilenemez enerji kaynakları, artan nüfus yoğunluğu ve doğada kıt olması kısa bir gelecekte tükenebileceği tespit edilmiş olduğundan enerji kaynaklarından olup fosil kaynaklar olarak adlandırılır. Yenilenebilir enerji kaynakları ise; kullandıkça bitmeyecek doğada sınırsız kabul edilen ve gelecekte tükenmeden kalabilecek kendisini yenileyebilen kaynaklar olarak adlandırılır.

Enerjinin herhangi bir mübadeleye ya da dönüşüme uğramamış biçimine birincil (primer) enerji denilmektedir. Birincil enerji kaynakları; petrol, kömür, doğal gaz, nükleer, hidrolik, biyokütle, dalga, gel-git, güneş ve rüzgardır. Birincil enerjinin transformasyon sonucu elde edilen enerji de ikincil (sekonder) enerji biçiminde tarif edilmektedir. Bunlar; elektrik, benzin, mazot, motorin, kok kömürü, ikincil kömür, petrol, hava gazı, sıvılaştırılmış petrol gazı (LPG) bu tip enerji kaynaklarındandır(Kaya et al., 2018).

İnsanoğlu hayatı boyunca çeşitli kaynakları enerji ihtiyacını karşılamak amacıyla kullanmıştır. Bazı ülkeler enerji kaynakları az bulunduğundan ihtiyaçları olan enerjiyi sağlamak için alternatif enerji kaynakları aramaya başlamışlardır ve enerji kaynaklarının bulunduğu bölgelere taşınmıştır. Bazı ülkelerde bulunduğu bölge de yeterince enerji kaynağının olduğuna inanmış, keşfettikleri yeni enerji kaynaklarını kullanmayı amaçlamışlardır(Atçı, 2020).

Enerji yaşamın devamlılığı için büyük önem taşıyan ve etkisini yaşamın birçok aşamasında gösteren bir olgudur. Bunlara örnek verecek olursak ev yaşam alanlarında, teknolojinin her alanında ve bunun gibi birçok yaşamsal faaliyetlerde enerjisiz bir yaşam düşünülmemektedir(Yapar, 2020). Bu doğrultuda geçmişten günümüze artan nüfus yoğunluğu ve teknolojinin giderek gelişmesinden dolayı enerji ihtiyacı artmaktadır. Artan nüfus ve teknolojik gelişme ile birlikte enerji talebi ile enerji arzı arasında açıklık meydana gelmesine neden olmuştur. Tabiatı da kıt bulunan kaynaklardan biri olan enerji neredeyse hepsini fosil yakıtlar olarak adlandırılan kömür, petrol, doğal gaz gibi yakıtlardan elde etmektedir(Ürün ve Soylu, 2016). Çağımızda, küresel ısınma ve kirlilik enerji temin etmek için fosil molekül esaslı yakıtların çoğunluk olarak kullanılmasının da etkisiyle evrendeki yaşamsal döngüyü tehdit edecek bir boyuta varmıştır. Bundan dolayı günlük yaşamda ve teknolojiye kullanılması zorunlu elektrik enerjisinin, evrende en az zarar verecek şekilde üretimi, gönderimi ve tüketiminin gerçekleştirilmesi konusu çözülmesi gereken en önemli sorunlardan biri haline gelmiştir(Kapluhan, 2014). Hem

fosil yakıt rezervlerinin giderek azalması hem de çevreye vermiş olduğu zarardan dolayı enerji ihtiyacını karşılamak için alternatif enerji kaynakları aramaya başlanmıştır. Doğa da sınırsız olması enerjiye dönüştürülürken çevre dostu, az maliyetli ve fosil yakıtlarına alternatif olarak yenilenebilir enerji kaynakları bulunmuştur.

1.2. YENİLENEBİLİR ENERJİ KAYNAKLARI

Doğada devamlılığı sağlanan enerji kaynakları yenilenebilir enerji kaynakları olarak tanımlanır. Yenilenemeyen enerji rezervlerinin kullanılabilme sürelerinin kıt olması yenilenebilir enerji kaynaklarına olan ihtiyacın artmasına ve alternatif olarak yenilenebilir ve maliyeti bakımından çok fazla olması enerji kaynaklarının da hayatımıza geçmesine neden olmuştur. Yenilenebilir enerji kaynakları hidrolik, güneş, biokütle, rüzgar, jeotermal, dalga, gel-git ve hidrojen olarak sınıflandırmaktadır(Özmen, 2018).

1.2.1. Hidrolik Enerji

Hidrolik enerji kaynağı sudur. Bu sebeple elektrik santralleri su kaynağı üzerine inşa edilir. Elektriği uzun mesafelere ileten teknoloji bulunduktan sonra hidrolik enerji daha da çok talep görmüştür.

Hidroelektrik santraller akan suyun kuvvetini elektriğe dönüştürürler. Akan su içindeki enerji kuvvetini suyun akış veya düşüş hızı tayin eder. Büyük bir nehirde akan su büyük miktarda enerji taşımaktadır. Yüksekliğin çok olduğu yerlerde suyun akış hızı fazla olduğundan dolayı bu santraller yüksek bölgelerde daha verimli olmaktadır. Hidroelektrik santrallerde akan suyun enerjisi temel alındığından balıkçılığı geliştirmede, ulaşımı kolaylaştırmada, sulamada ve en çok da enerji üretiminde kullanılmaktadır. Kurulan santralde borular içine alınan su türbinlerden geçer ve elektrik üretimi için pervane gibi kolları olan türbinlerin dönmesini sağlar. Türbinler jeneratörlere bağlıdır ve mekanik enerjiyi elektrik enerjisine dönüştürürler(Ağış, Aydın, Armağan, & Kılıkış, 2020).

1.2.2. Dalga Gel-Git Enerji

Gel-git oluşumu ay, güneş ve dünyanın çekim gücü ile merkez kaç kuvvetleri arasındaki iletişimi sonucunda oluşan enerjidir. Gel-git olayı rüzgarın gücüyle de oluşan denizlerdeki dalgalanmaların çok yüksek seviyeye ulaşmasıyla enerji meydana gelir. Oluşan enerjiyi de elektrik enerjisine dönüştürür. Dünyada gel-git gücü potansiyeli 100000 MWⁱ olarak bilinmektedir. Gelgit ile oluşan gücün büyüklüğünün %68'i ay.

%32'si ise güneşin dünyaya olan uzaklığına bağlıdır. Yeryüzünde 3000 GW¹ büyüklüğünde gelgit kapasitesi bulunmaktadır fakat bu dalgaların sadece %2'si gelgit enerjisine dönüştürülmektedir(Özdamar, 2005).

1.2.3. Jeotermal Enerji

Jeotermal enerji yenilenebilir, devamlılığı olan, tükenmez, maliyeti düşük, güvenilir, çevre dostu, yerli ve yeşil bir birincil enerji kaynağıdır. Jeo-yerküre, termal-ısı anlamına gelmektedir(Toka ve Şahin, 2006). Jeotermal enerjinin oluşumu yerkürenin kendiliğinden oluşan ısını, yer kabuğunun derinliklerinde toplanmış olan basınç altındaki sıcak seyyan (su, buharı, gaz) ve sıcak kuru kayaların içerdiği enerjiye jeotermal enerji denir(Yılmaz, 2012).

1.2.4. Biyokütle Enerji

Biyokütle enerjisi sınırsız bir kaynak olması, her yerde kolayca elde edilmesi, özellikle kırsal bölgeler için sosyo-ekonomik gelişmelere yardımcı olması, uygun ve az maliyetli olması açısından da önemli bir enerji kaynağıdır. Biokütle enerjisi, ağaçların, mısır, buğday gibi özel olarak yetiştirilen bitkileri, otları, yosunları, atılan meyve ve sebze atığı gibi tüm organik çöpleri, hayvan dışkıları, gübre ve sanayi atıklarını saymak mümkündür. Bitkilerin fotosentezi sırasında kimyasal olarak özellikle selüloz biçiminde depo edilen ve daha sonra farklı şekillerde kullanılan enerjidir(Topal ve Topal, 2008)

1.2.5. Hidrojen Enerji

Hidrojen dünyada en çok bulunan elementlerinden biridir. Su, hidrojen ve oksijenden oluşur, akarsu ve denizlerde çok miktarda bulunmaktadır. Hidrojen doğada saf halde bulunmaz. Ancak çeşitli yöntemlerle elde edilebilir. Bu sebeple yenilenebilir bir yakıttır. Bunun yanında yakıtlar içerisinde çevresel açıdan en temizidir. Birincil enerji kaynakları kullanarak hidrojen üretilip bunun gereksinim duyulan yerlere iletilerek çeşitli yöntemlerle enerjiye çevrilmesine hidrojen enerji sistemi denir(Üçgül ve Elibüyük, 2017).

1.2.6. Rüzgar Enerjisi

Rüzgar enerjisi, eski yıllardan beri kullanılan bir enerji kaynağıdır. Eski yıllarda çoğunluk olarak yel değirmenleri yardımıyla buğdayı un haline getirme ve su

¹ 1 milyar watt'a karşılık gelen elektrik ölçü birimi olan gigawatt büyük elektrik birimleri arasında sayılabilir.

pompalamak için kullanılırken günümüzde ise yaygın olarak elektrik üretimi için kullanılmaktadır(Kılıç, 2016). Havanın yüksek basınçtan alçak basınca geçerken oluşan yatay basınca rüzgar denir. Rüzgar kuvveti evrenin farklı oranda ısınmasından kaynaklanan yüksek ve alçak basıncın çarpışması ile oluşan enerjiye rüzgar enerjisi denir(Sekin, 1999). Bu hava hareketinin hızına göre hafif veya kuvvetli rüzgarlar oluşmaktadır. Rüzgarın esme şiddetine göre hızı da değişik değerler almaktadır. Rüzgarın esmesi en hafif şiddette olduğu gibi fırtına ve daha güçlü akımlar halinde de olabilmektedir(İlkılıç, 2003).

Rüzgar enerjisi yenilenebilir, kullanılabilir ve çevreye zarar vermediğinden dolayı bir temiz enerji kaynağı olarak bilinmektedir. Rüzgar enerjisi teknolojisi, diğer enerji kaynaklarına oranla daha maliyeti azdır. Kolayca ulaşılan ve aynı zamanda kullanımında da büyük bir teknoloji kurulumu gerektirmez. Böylelikle rüzgar gücü yoğunluğu çok olan yerlerde rüzgar enerji tribünleri kurularak ekonomiye büyük ölçüde katkı sağlamaktadır(İlkılıç, 2003).

1.2.7. Güneş Enerjisi

Güneş Sistemi, kısaca Güneş ve güneşin çekim kuvveti etkisiyle etrafına toplanan gök cisimleri topluluğudur. Sonsuzluğun yapı taşlarından olan gezegenler ve uyduları. gök taşları, kuyruklu yıldızlar, asteroitler bu topluluğu oluşturan temel ana taşlarıdır. Sistemin adı olan güneş temel yıldız olmakla birlikte orta büyüklükte bir yıldızdır. Buna karşılık bu sistemin toplam hacminin %99,8'i güneşe sahiptir. Dünyamız da katı olarak gözüke bile katı bir yüzeye sahip değildir, dünyamıza ışık ve ısı saçan bu gaz topunun yaşı 4.5 milyar yıl olduğu söylenmektedir. Güneş enerjisi, kaynağını güneşteki füzyon olayından alan temiz bir enerjidir. Güneş kütleinin saniyede 5 milyon tonluk bir kısmı ısı ve ışığa dönüşmektedir. Bu enerjinin 1010 MW'lık kısmı dünyaya ışık olarak ulaşır. Bu çok yüksek bir değer olsa bile, güneş enerji teknolojileri yardımıyla bu ışınımın ancak bir kısmı enerjiye dönüştürülebilir(Kapluhan, 2014).



Şekil 2. Güneş Sistemi

Kaynak: (Sarigül, 2016)

Güneş dünya için başlıca bir enerji kaynağıdır. Güneş yarıçapı 700.000 km (dünya yarıçapının yaklaşık 109 katı), kütlesi 2×10^{30} kg (dünya kütlesinin yaklaşık 330.000 katı) olan bir yıldızdır (Demir, 2016)

Güneş evrenimize ve diğer tüm gezegenlere enerji saçan sınırsız denebilecek kuvvete sahip tek enerji kaynağıdır. Termo-nükleer² bir reaktör³ olan güneşin birim çapından birim vaktinde türlü dalga boylarında 62 MW/m^2 enerji yayılmakta ve güneşin her yüzeyinden yayılan enerjinin yalnızca iki milyardan biri yeryüzüne gelmektedir. Dünyaya gelen ortalama güneş ışıınımı şiddeti $0-1000 \text{ W/m}^2$ arasında değişmektedir (Doğan, 2006). Güneş enerjisinden faydalanma konusundaki araştırmalar özellikle 1970'lerden sonra hızla artmıştır. Güneş enerjisi panelleri teknolojik olarak gelişme göstermekte, maliyet açısından daha az ve doğa dostu olarak bilinen temiz bir enerji kaynağıdır. Güneş, nükleer enerji dışındaki tüm enerjilerin dolaylı veya doğrudan enerji kaynağıdır (Yolcan ve Köse, 2020) .

Güneş enerjisini ısı enerjisine dönüştürür ve üretilen ısı enerjisinin doğrudan

2 Yalnızca çok yüksek sıcaklıklarda, hafif elementler arasında oluşan (çekirdeksel tepkime).

3 Yakıt olarak çevre havayı kullanan ve pervanelerin yardımı olmaksızın doğrudan doğruya tepkiyle çalışan, iki ucu açık boru biçiminde itici.

kullanımını yani sıcak su kazanı veya ev ısıtma sistemi olarak ya da elektrik üretimi için tekrar kullanılmasını sağlar. Yapısal olarak farklı ayna konumlarında güneş ışığını toplar, yoğunlaştırılmış bir hale getirerek yüksek sıcaklıkta ısı dönüşümü sağlar ve panel içerisinde kullanılan akışkan, yoğun ısı ile birleşerek buhar halini alır(Doğan, 2019).

Güneşin temel yapısında oluşan füzyonda ortaya çıkan bir bölüm enerji dünyaya yansır. Yeryüzüne gelen ışınım, kurulan güneş panellerine yansır, kolektörlerin yardımıyla depolanan enerji ısı ve elektriğe dönüşür. Güneşten alınan enerji ile soğutma, ısınma ve elektrik üretimi için, ısıtmada, soğutmada veya elektrik olarak kullanılmamakta, hayatımızın her alanında kullanılmaktadır. Örnek verecek olursak yeni üretimine başlayan güneş enerjili otomobiller, sokak aydınlatma lambaları. Jeneratörler, elektronik cihazlar hatta vücudumuzun bile güneş enerjisine ihtiyacı vardır. Ev ve apartmanların çatılarında görülmekte olan güneş enerji adı verilen kolektörler ile su ısıtılarak, evin sıcak su gereksinimini ya da ısıtma sistemi kurularak ısınma gereksinimi içinde kullanılır. Güneş, sınırlı yeraltı kaynaklarına alternatif enerji kaynağı olarak bilinen sınırsız, yenilenebilir doğal enerji kaynaklarının en temelini oluşturmaktadır(Özen, 2021).

1.2.7.1. Güneş Enerjisi ile İlgili Temel Kavramlar

Soğurucu: Güneş kolektörünün içinde güneşten gelen radyasyonu olabildiğince fazla toplayan ve yakalayan parçadır. Isı transferi sağlayan akışkan soğurucudan ya da soğurucuya eklenen kanallardan akmasına denir.

Soğurma Çarpanı: Soğurma çarpanı, gelen emilmiş radyasyonun, gelen radyasyona oranıdır. Emicilik kapsamında değişikliğe yol açan tüm materyallerin yarattığı sonuçtur.

Soğurum Kliması: Büyük bir shaft girdisine ihtiyaç duymadan soğurma ve salma işlemi esnasında bir serinleme efektine ulaşmasıdır.

Hava Kütlesi: Direkt güneş radyasyonunun seyrinde atmosferden itibaren izlediği yolun uzunluğudur.

Açıklık: Güneş kolektöründe radyasyonun öncelikli olarak soğurucuya geçtiği açıklıktır.

Dış Sistem: Bulutlu periyotlarda ya da gece saatlerinde güneş enerji sistemine yedek sağlayan sistemdir.

Azimuth Açısı: Belirlenen noktanın kuzey güney düzlemindeki açısı ve yatay düzlemde güneş-dünya hattının yansıtımıdır.

Batarya: Tersinir kimyasal reaksiyonları kullanan elektrik enerjisi depolama sistemidir.

Radyasyon Demeti: Belirlenen yüzeye gelen radyasyon ve güneşin disk gibi gözlemlenen görüntüsünden çıkarılan 3 düzlemin o yüzeyde oluşturduğu açıdır.

Brayton Döngüsü: Jet motorlarında kullanılan termo-dinamik döngüyü kullanan bir ısı motorudur.

Kadmiyum Sülfür: Kadmiyum metalinden elde edilen sarı-portakal renge sahip kimyasal alaşım. Yarı iletken olarak Kadmiyum Sülfür her zaman n-tipi'dir.

n-tipi: İletken bantta serbest elektronların olması için katkı maddeleriyle saflığı bozulmuş yarı iletkenidir.

Kovuk Alıcısı: Güneş radyasyonunun bir ya da daha fazla açıklıktan içeride bulunan ısı soğurucu yüzeylerde soğurulması için girmesini sağlayan giriş noktasındaki kovuk şeklindeki alıcıdır.

Kolektör: Güneş radyasyonunu yakalayan ve onu enerjinin kullanılabilen herhangi bir tipine çevirebilen tüm cihazlardır.

Kolektör Verimliliği: Kolektör tarafından sağlanan enerjinin, kolektöre yansıyan enerjiye oranıdır.

Kolektör Verimlilik Faktörü: Kolektör tarafından sağlanan enerjinin, kolektörde bulunan soğurucunun ortalama akışkan sıcaklığında çalışması sonucunda sağladığı enerjiye oranlanır.

Kolektör Akış Faktörü: Kolektör tarafından sağlanan enerjinin, kolektörde bulunan soğurucunun ortalama akışkan sıcaklığının akışkan giriş sıcaklığına eşit olması durumunda sağladığı enerjiye oranıdır.

Kolektör Eğim Açısı: Kolektörün açıklık düzleminin yatay düzleme göre yaptığı açıdır.

Yoğunlaştırma Oranı: Kolektörlerde açıklığın alıcı alana oranıdır.

Yoğunlaştırıcı Kolektörler: Açıklıktan soğurucuya radyasyonu geçirirken.

reflektörler ve lensler yardımıyla güneş ışığını yönlendirerek yoğunlaştıran kolektörler.

Kaplama Tabaka: Güneş enerjisinin sera etkisiyle sıkışmasını engellemek için kolektörüne soğurucu tabakasına kaplanan şeffaf materyaldir.

Yoğunlaştırıcı Parabolik Çanak Kolektör: Birbirine bakan iki parabol yardımıyla radyasyonu yoğunlaştıran kolektör sistemidir.

Sapma: Dünya Güneş düzlemiyle ekvator düzlemini (Pozitif Kuzey) birbirine bağlayan açıdır.

Dağınık Radyasyon: Yatay düzlemde belirlenen noktaya düşen, atmosferik etkiler nedeniyle saçılan ve geniş açıyla ulaşan radyasyondur.

Direk Radyasyon: Belirlenen yatay düzleme güneşten ulaşan radyasyonun atmosferik etkilerle dağılmadan dar bir açıyla ulaşmasıdır.

Direk Sistem: Kişi tarafından kullanılacak sıcak suyun kolektörlerden direk ulaşmasını sağlayan güneş ısı sistemidir.

Havasız Tüplü Kolektörler: Tüp ve soğurucu arasında havası alınmış bir cam tüp kullanandır.

Evaporatör: Akışkanın sıvıdan buhar haline dönüşümünün gerçekleştiği ısı aranjörüdür.

Dünya Dışı Güneş Işınımı: Bir yüzeye ulaşan atmosfer limitindeki güneş radyasyonudur.

Sabit Plakalı Kolektörler: Hem direk hem de dağınık radyasyonu toplayabilen sabit kolektördür.

Fresnel Kolektörü: Solar radyasyonunu alıcı üzerine odaklamak için Fresnel Lensi'ni kullanan yoğunlaştırıcı kolektördür.

Geometrik Faktör: Normal dışı yansıma durumlarında yoğunlaştırıcının açıklık alanına etki eden azalmanın ölçümüdür.

Kaplama: Soğurucunun yüzeyini kaplayan cam, plastik ya da başka şekilde saydam materyaldir.

Toplam Güneş Işınımı: Yatay bir düzleme ulaşan yarı küreye ait güneş radyasyonu. Hem ışın demetini hem de dağınık radyasyonu içerir.

1.2.7.2. Güneş Enerjisinin Tarihi Gelişimi

Milattan önce de başlayan çalışmalar, teknolojik gelişmeler ve bilgi birikimi ile çağımıza kadar devam etmiştir.

Kaynaklara göre M.Ö 400 yılında doğan Yunan filozof Sokrates, güneşten yararlanmak amacıyla evlerin güney cephelerine diğer cephelerden daha fazla pencere konulmasını sağlamıştır. M.Ö 218 yılına gelindiğinde ise ünlü matematikçi Arşimet, bugün İtalya’da bulunan Sirakuza şehrini Roma ordularından korumak amacıyla içbükey aynalarla güneş ışınlamını odaklayarak Roma filolarını yakmıştır(URL4, 2021).



1600	Galileo Galilei'nin Avrupa'da yüzyıllardır kullanılan mercekleri geliştirmesiyle güneş ile ilgili araştırma yapmak kolaylaşmış ve dolayısıyla bir enerji kaynağı olarak kullanılmasının önemi artmıştır.
1700	Fransız mühendis Belidor güneş enerjisi ile çalışan bir su pompası icat etmiştir.
1860	Fransız bilim adamı Mouchot, parabolik aynalar aracılığı ile güneş ışınımını odaklayarak küçük bir buhar makinesi icat etmiştir. Mouchot aynı zamanda güneş pompaları ve güneş ocakları üzerinde sayısız çalışma yapmıştır.
1900	Amerikalı mühendis Frank Shuman, yaptığı çalışmalar sonucunda güneş enerjisi ile su ısıtarak buhar elde etmiştir.
1860-1914	Güneş enerjisi alanında 50'den fazla patent alınmıştır.
1914	1.Dünya Savaşı'nın etkisiyle petrol önem kazanmış ve güneş enerjisi adına yapılan çalışmalar araştırma boyutunda kalmıştır.
1973	1973 yılında petrol krizinin ortaya çıkması insanları yenilenebilir enerji kaynaklarından daha fazla yararlanmaya teşvik etmiştir.
1984	İlk endüstriyel tip enerji üretimi 1984 yılında Los Angeles'ta Luz Inc. tarafından gerçekleştirilmiştir. Kurulan parabolik aynalı sistem ile 354 MW güç üretimi sağlanmıştır.
1990	10 MW'lık Kaliforniya'da, diğeri de 30 MW'lık Ürdün'de olmak üzere iki adet güneş kulesi sistemi kurulmuştur.
2000	Başında güneş enerjisi konusundaki çalışmalar ve yatırımlar artarak devam etmiştir.
2006	Dünya fotovoltaik üretimi, toplam 2.520 MWp parça kapasitesine ulaşmıştır.
2014	Türkiye'de Güneş enerjisinde 2014'te 40.2 megavat iken 2015'te 248.8 megavat seviyesine ulaştı. Bu kapasite, 2016'da 832.5 megavat, 2017'de 3 bin 420 megavat, 2018'de 5 bin 62 megavat, 2019'da 5 bin 595 megavat oldu.
2018	17 Temmuz 2018 tarihinde Alanya Belediyesi ile Akdeniz Elektrik Dağıtım Şirketi arasında bağlantı protokolü imzalanan ve 26 Aralık 2019 tarihinde yapım işi tamamlanarak ön kabulü gerçekleşen Alanya Belediyesi GES-4 Projesi başlatılmıştır.


Şekil 3: Güneş Enerjisinin Tarihi Gelişimi

Kaynak:(Ekoloji.net, 2017 <https://ekolojist.net>) yararlanarak düzenlenmiştir.

1.2.7.3. Dünya'daki Güneş Enerjisi

Dünyamızın şekli nedeniyle, coğrafik şekiller ve konumlar dünya üzerinde her bölgeye ve her ülkeye aynı açı ve düzlemle gelmemektedir.

Şekil 4'te de görüldüğü üzere mavi kısım hiç güneş almayan yeşil kısım çok az ve sırası ile kırmızı olan kısım ise aşırı güneş alan bölgelerdir.



Şekil 4. Dünya Güneş Enerjisi Haritası

Kaynak:(Özen, 2021)

1.2.7.3.1. En Çok Güneş Alan Bölge ve Ülkeler

Afrika'nın büyük bir kısmı özellikle de Sahra Afrika olarak adlandırılan ve tamamı çöl olan bölge. Avustralya ve Amerika'nın orta bölgesi en çok güneşi gören bölge olarak bilinmektedir ve dünyanın diğer bölgelerine göre güneş bakımından en bol olan bölgedir. Ülkemiz bu haritadaki ölçeğe göre m²'ye, yıllık 1500–2000 kWh civarında güneş ışıının ulaştığı, ortalamanın fazlasıyla üzerinde ve çok şanslı bir ülke olarak bilinmektedir. Güneş ışığı alan bölgelerin hemen hemen hepsi çölleri kapsamaktadır. Bu bölgeler genellikle yerleşim ve yatırım bölgelerine çok uzak kalmaktadır. Öte yandan bu bölgelere yatırım yapılsa bile üretilen enerjinin ulaşımı için ayrı bir maliyet gerekmektedir. Bundan dolayı Türkiye, İspanya gibi güneş enerjisini çok alan ülkeler yatırım olanakları fazla, tüketim merkezleri benzer şekilde özellikleri göz önün de bulundurursak dünya çapında bulunduğu ve coğrafi şekilleri bakımından en şanslı

ülkeleri dikkatleri üzerinde toplamaktadır. Fakat Afrika'nın kuzey kıyıları yerleşim ve ulaşımı kolay olan bölgelere yapılacak enerji yatırımlar da dikkate değer bir verimlilik getirebilir.

Son zamanlarda birçok ülkenin, güneşten gelen ışıını enerjiye dönüştürmek için önemli adımlar attığını görmekteyiz. Çevre yapısını, temizliğini ve kaynakların devamlılığına çok fazla önem veren Avrupa birliğindeki ülkeler bu yapının en başında yer almaktadırlar. Gerek Avrupa ülkelerinin kıt kaynaklar ile enerji üretiminde karşı karşıya gelmeleri, gerekse Avrupa müktesebatının çevreyi ve doğa yapısının korunmasını mecbur kılması Avrupa ülkeleri için bu konu üzerinden yaptırımlar uygulayarak yatırım yapılmasında zorunluluklar getirmiştir(Özen, 2021) .

1.3.7.3.2. Dünyada Güneş Enerjisi Üretiminde Öne Çıkan Ülkeler

Almanya, Danimarka, İspanya ve benzeri ülkeler güneş enerjisi üretimi ve teknolojisi konusunda Avrupa'nın önde gelen ülkeleridir. Dünya lideri olma yolunda yürüyen Almanya, güneş enerjisi konusunda önemli bir ülkedir. Danimarka ülkesi güneş pillerinin üretiminde birinci sıraya gelmeye yaklaşmakta ve hızla büyüme göstermektedir. İspanya ülkesi ise fosil yakıtlar konusunda Avrupa'nın en yoksul ve kıt kaynağa sahip ülkesi olduğundan yenilenebilir enerji kaynaklarından enerji üreteceği bütün alanda Avrupa'da ilgi çekici çalışmalar ve araştırmalar yapmaktadır(Özen, 2021).

Tablo 1. En Çok Güneş Enerjisini Alan Ülkelerin Dağılımı

Ülkeler	Güneş Enerjisi Gücü(WM)
Almanya	32.411
İtalya	16.361
Çin	8.300
Amerika	7.777
Japonya	6.914
İspanya	5.166
Fransa	4.003
Belçika	2.650
Avustralya	2.412
Çek Cumhuriyeti	2.072
İngiltere	1.829
Yunanistan	1.536
Hindistan	1.205
Güney Kore	1.064
Bulgaristan	908
Kanada	765
Slovakya	523
Avusturya	418
İsviçre	416
Danimarka	394


Kaynak:(Özen, 2021)

Dünyada güneş ışıını kullanımlarına baktığımızda birinci sırada Almanya, ikinci sırada İtalya'yı görmekteyiz. Güneş günün saatinde uzun sürede havada kaldığından dolayı İtalya bu konuda diğer ülkelere göre daha iyi konumdadır. Ülkelerin güneş enerjilerine yönelmelerinin en büyük nedenlerinden biri de sera gazlarının salınımını azaltmak içindir. Bu konuda çalışma yapan diğer bir ülke Japonya'dır. Ülkenin genelinde pek çok fabrikada güneş enerji üretimi yapılmaktadır. Japonya, İspanya ve Amerika Birleşik Devletleri takip etmekte, yaptıkları yatırımlar ve pek çok çalışmayla öne çıkmaktadırlar(URL1, 2021).

1.2.7.4. Türkiye'de Güneş Enerjisi

Türkiye yenilenebilir enerji kaynakları bakımından zengin sayılamayacak bir ülkedir. Toplam jeotermal, hidrolik enerji ve kömür rezervi potansiyeli toplamı dünya bulunan kaynakların %1'ini içermektedir. Doğalgaz ve petrol bakımından yok denecek kadar azdır(Saner, 2015). Enerji bakımından dışa bağımlı bir ülke olduğu için kalkınması ve gelişmesi açısından enerji önemli rol oynamaktadır. Ülkemizin coğrafi konumu değerlendirildiğinde güneş enerjisinin yeryüzüne geliş açısı oldukça uygundur. Bu nedenle, Türkiye'nin yenilenebilir enerji kaynakları arasında en çok olanı güneş enerjisi olarak bilinmektedir (Yarkan, 2006).

Türkiye'de 1960'ların başlarında yenilenebilir enerji kaynakları olarak güneş enerjisi ilk defa alternatif enerji kaynağı olarak kullanılması hedeflenmiş ve yatırımcılar, üniversitelerde verilen akademik çalışmalar ile bu konu üzerinde durmuşlardır. 1970'lerin ortalarında ise dünyadaki güneş enerjisi teknolojisindeki gelişmeler ile birlikte, ülkemizde de özellikle güneş enerjisinin ısı çalışmalarını konusu akademide, devlet ve endüstri açısından ilgi görmüştür ve güneş enerjisi çalışmaları 1970 yılından itibaren hızla gelişme göstermiştir(Eskin, 2006).




Şekil 5. Türkiye Güneş Enerjisi Haritası

Kaynak:(Ekoloji.net. 2017).

Türkiye güneş enerjisi haritası incelendiğinde, tüm canlılar için temel enerji kaynağı olan güneşten endüstriyel olarak da fazlasıyla verim alabileceğimiz görülmektedir. Yapılan araştırmalara göre güneşin enerjisi önümüzdeki 5 milyar yıl daha aynı şekilde devam edecektir. Bu da insanoğlu için güneşin vazgeçilmez ve en sürdürülebilir kaynaklardan biri olduğunu göstermektedir. Türkiye güneş enerjisi haritası incelendiğinde ülkemizde toplam 1644 adet güneş enerji santralinin bulunduğu görülmektedir. Ülkemizde bulunan tüm santrallerin toplam enerji gücü ise 1.362.60 MW'dir(URL7, 2017).

Enerji Bakanlığı'nca 2020 yılında hazırlanan Türkiye'nin Güneş Enerjisi Potansiyeli Atlası' na göre yıllık toplam güneşlenme süresi 2.737 saat, yıllık toplam gelen güneş enerjisi 1.527 kWh/m² yıl olduğu tespit edilmiştir. Tablo1'de görüldüğü gibi güneş enerjisi elektrik enerjisinin %7'sini oluşturmaktadır. Bu tespitler sonucunda da yatırımlarımızı dış ülkelere yapmaktansa güneş ışıınımı zengin bir ülke olduğumuz için güneş panellerine yatırım yapılması öngörülmüş ve çalışmalar başlamıştır.



KURULU GÜÇ : 68 719,1 MW

Şekil 6. Türkiye Elektrik Enerjisinin Kullanım Oranı

Kaynak:(URL6, 2021)

Türkiye'nin temel enerji kaynakları; Tablo1'de görüldüğü gibi petrol, linyit, kömür, doğalgaz, jeotermal ve hidrolik enerji olarak sıralanmaktadır. Türkiye'nin kullanabileceği enerji üretimine rağmen tüm enerji ihtiyacının ancak % 48' ini elde etmektedir. Yenilenebilir olmayan enerji ve fosil kaynakları potansiyeli açısından yoksul bir ülke olan ülkemiz direkt doğalgaz, elektrik enerjisi, petrol ve yüksek kalitede kömür ithali için her sene milyonlarca dış ülkelere yatırım yapmaktadır(Dinçer, 2011).

1.3. İLGİLİ ÇALIŞMALAR

Geçmişte ve günümüzde olduğu gibi bundan sonraki yaşam sürecimizde de en önemli enerji kaynağı olan güneş enerjisi için ışıınım miktarını tahmin etmek ve bu konuda hataları en aza indirmek farklı yöntem ve teknikler ile analizinin yapılması için birçok uzman ve araştırmacı tarafından ele alınmış olup literatürde güneş ışıının tahmini yapan birçok çalışma bulunmaktadır. Literatürde bulunan çalışmaları aşağıdaki gibi özetleyebiliriz.

Mengeş ve Sonmete (2005), Konya' da 2000-2002 yıllarında yatay düzleme gelen güneş ışıının aylık ortalama değerleri arasında var olan modeller ile hesaplanarak sonuçları karşılaştırmışlardır. Hesaplamalarda kullanılan modellerin regresyon katsayıları hesaplanmış ve bu katsayılar toplam güneş ışıının tahminlemede kullanılmıştır. Tahminin standart hatası (RMSE) değerleri kullanılarak en uygun model seçilmiştir.

Bununla birlikte ölçülen değerler arasındaki farkın yüzdesi $|e|$ belirlenmiştir. Elde edilen sonuçlara göre en iyi model kullanılan mevcut modellerden olan Samuel modeli olmuştur. Araştırma sonucuna göre. Samuel Modelinin (RMSEort 0.471) en iyi değeri sağladığını belirlenmiştir(Mengeş ve Sonmete, 2005)

Deniz ve Atik (2007), Zonguldak iline ait 1995 ile 2004 yılları arasındaki aylık ortalamalar halinde on yıllık toprak sıcaklığı, hava sıcaklığı, rüzgar hızı, nem miktarı, deklinasyon açısı, güneş ışıınımı alımının gün uzunluğuna oranı ve aylık ortalama atmosfer dışı güneş ışıınım şiddeti verileri Devlet Meteoroloji İşleri Genel Müdürlüğü'nden (DMİGM) talep edilmiş ve talep edilen veriler regresyon analiz yöntemi ve yapay sinir ağları (YSA) yardımıyla modeller elde edilmiştir. Elde edilen iki model arasında karşılaştırmalı olarak analizleri yapılmıştır. Oluşturulan modeller kullanılarak Ocak/2005 ve Aralık/2005 arasındaki toplam güneş ışıınımının aylık ortalamaları hesaplanmış ve 2005 yılında ölçülmüş olan veriler ile karşılaştırma yapmıştır. Ölçülen güneş ışıınım şiddeti tahmininde kullanılan her iki yönteminde oldukça düşük hata değerlerine sahip oldukları belirlenmiştir. Her iki yönteminde yüksek korelasyon katsayısı ve düşük hata değerlerine sahip olduğu tespit edilmiş olup güneş ışıınım şiddeti tahminlerinde etkin olarak kullanılabileceği önerilmiştir. Karşılaştırılan modellerden regresyon analiz yönteminin YSA'dan daha yakın değerler sağlayacağı görülmüştür. Ölçülen değerler ile hesaplanan değerler arasında her iki yöntem uygulandığında regresyon analiz yöntemleri %1.28 ve yapay sinir ağlarında ise % 3.25'lik bir ortalama bağıl hata olduğu tespit edilmiştir(Deniz ve Atik, 2007) .

Bakırcı (2009) çalışmasında Erzurum ili için yatay yüzeye gelen anlık global güneş ışıınımını, basit bir hesaplama metodu kullanılarak ölçülen değerler ile karşılaştırmıştır. Yapılan karşılaştırma sonucunda, hesaplanan değerler ile ölçülen değerler arasında başarılı bir uyum içinde olduğu sonucuna varmıştır. Çıkan sonuçlar. önerilen hesaplama metodunun Erzurum'da yatay yüzeye gelen anlık global güneş ışıınımını tahmin etmek için kullanılabileceğini belirlemiştir. Güneş ışıınım verilerinin bulunmadığı konumlarda uygun korelasyonlar oluşturularak kullanılan parametre belirlenebilmektedir. Sonuçta hesaplanan ve ölçülen değerler arasında iyi bir uyum olduğu gözlemlenmiştir(Bakırcı, 2009).

Reikard (2009)'a göre yatay yüzeye gelen güneş ışıınımını belirleyen temel fiziksel süreçlerin karmaşık doğasını modellemek için Yapay Sinir Ağları(YSA), Bulanık Mantık

(BM) ve Hibrit Sistemler (GA/YSA, YSA/BM) modelleri uygun bulmuştur(PV tesislerinin güç çıkışı gibi). Genellikle doğrusal olmayan atmosferik olayları tanımlamak için ARMA ve ARIMA yöntemi gibi onun varyasyonlarını içeren diğer regresyon yöntemleri kullanılmaktadır(Reikard, 2009).

Tektaş (2010), hava tahminleriyle ilgili yapmış olduğu çalışmada örnek olarak İstanbul iline ait Kadıköy ilçesine bağlı Göztepe mahallesinin 2000-2008 yılları arasındaki verileri kullanarak tahminleme yapmıştır. Tahminleme yapmak için nöro-bulanık sinir ağlarını kullanmıştır. Modeli oluştururken günlük ortalama sıcaklık (kuruluş), hava basıncı ve rüzgar hızı değişkenleri kullanılmış olup Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Otomatik Regresif Hareketli Ortalama (ARIMA) modelleri ile tahminleme yapılmıştır. ARIMA ve ANFIS tekniklerinin etkinliğini sağlamak için farklı bir eğitim ve test veri seti kullanan farklı modeller test edilmiştir. Analiz sonuçları üzerinde tahmin performansı, güvenilirliği ve verimliliğine göre en uygun model ve ağ yapısı belirlenmiştir. ANFIS ve ARIMA modellerinin MAE (Hareketli Ortalama Hatası), RMSE-R² (Kök-Ortalama-Kare hatası) kriterlerine göre performans karşılaştırmaları yapılmış sonuç olarak ANFIS verilerinin daha iyi sonuç verdiği gözlemlenmiştir(Tektaş, 2010).

Bıyık (2010) İstanbul iline ait hava kirliliği üzerinden çalışma yapmıştır. Çalışmasında 2002-2009 yıllarına ait (Sarıyer. Beşiktaş. Esenler. Yeni Bosna. Alibeyköy. Saraçhane. Üsküdar. Kadıköy. Ümraniye. Kartal)on istasyondan hava ile ilgili verileri almıştır. Değişken olarak Kükürt dioksit(**SO**₂). Partikül Madde (PM) ve Karbondioksit (CO). Azot dioksit **NO**₂ verilerini modele dâhil edip tahminleme yapmıştır. Tahmin yöntemleri olarak yapay zekâ teknikleri içerisinde bulunan Bulanık Mantık yöntemini kullanarak, hava kirliliğinin modellemesini yapmıştır. Çalışma sonucunda ise **SO**₂ ile PM değişkenleri arasında 0.609 ılımlı korelasyon bulunurken **SO**₂ ile CO değişkenleri arasında 0.824 güçlü, yüksek korelasyon, PM ile CO değişkenleri arasında 0.717 ılımlı ya da dikkate değer korelasyon hesaplamıştır. Çıkan analiz sonucunun yorumu ise **SO**₂ ile CO değişkenleri arasındaki kuvvetli etkileşimden dolayı bu iki parametre (Kükürt dioksit ve Karbondioksit gazları) hava kirliliğinin oluşmasında en önemli rol oynayan etken olduğu sonucuna ulaşmıştır(Bıyık, 2010).

Uslu (2011), çalışmasında 1923-2009 yıllar arasında Türkiye'deki elektrik enerjisinin tüketim verilerini kullanmış olup (YSA) ve Box-Jenkins yöntemlerinin

karşılaştırmasını yapmıştır. YSA için MATLAB R2008a programı yardımı ile bir girdi sinir ağı bir gizli katman ve bir çıktı sinir ağı ile ileri beslemeli geri yayılım yöntemini kullanmıştır. Zaman serisinde ise Eviews ve Minitab programları yardımı ile Otoregresif Model (AR) yöntemini yöntemi kullanmıştır. Sonuç olarak Box-Jenkins AR(1) analizin sonucu yapay sinir ağları analizindeki MAPE ye göre daha iyi sonuç elde etmiştir(Uslu, 2011).

Khatib vd.(2012), YSA kullanılarak güneş ışıınımı tahmini geliştirilmiştir. YSA modeli, dört girdi ve bir çıktı ile ileri beslemeli çok katmanlı algılama modeline dayanmaktadır. Araştırmada Malezya'daki 28 meteoroloji istasyonunun verileri kullanılmış ve ağı eğitmek için 23 istasyon, ağı test etmek için 5 istasyon kullanılmıştır. Girdiler enlem, boylam, gün sayısı ve güneş ışığı oranıdır; çıktı, netlik endeksidir. Geliştirilen ağı ile açıklık indekslerini tahmin etmek amaçlanmıştır. Netlik indeksleri daha sonra küresel güneş ışıınımını tahmin etmek için kullanıldı. Bölgelerden ölçülen güneş ışıınımları, küresel güneş ışıınımının bir fonksiyonu ve açıklık indeksi olan yayılan güneş ışıınımını hesaplamak için bir denklem türetmek için kullanıldı. Önerilen denklem, geleneksel denklemle karşılaştırıldığında, yayılan güneş ışıınımı tahmininde ortalama mutlak yüzde hatasını (MAPE) azaltmıştır. Sonuçlara göre, tahmin edilen küresel güneş ışıınımı için ortalama MAPE, ortalama sapma hatası ve ortalama karekök hatası %5.92, %1.46 ve %7.96'dır. Yayılan güneş ışıınımını tahmin etmede MAPE %9,8'di(Khatib, Mohamed, Sopian, & Mahmoud, 2012).

Baharin (2013) doğru ışıınım tahmini, şebekeye bağlı fotovoltaiik entegrasyonunun çoğalmasını kolaylaştırmaya yardımcı olan temel faktörlerden biridir. Veri güneş radyasyonunun saatlik değerlerini tahmin etmek için Malezya, Sepang'daki meteorolojik durum ölçümünden elde edilmiştir ve tahminleme tekniğı olan sinir ağı modelleri kullanılmıştır. Veriler, kusurlu değerleri ortadan kaldırmak ve daha hızlı ve güvenilir bir şekilde yakınsamaya yardımcı olmak için önceden işlenmiştir. Metodoloji, gelecekteki saatlik ışıınımı tahmin etmek için yıllık, üç aylık ve aylık sürelerin tarihsel ışıınım değerlerini kullanan Doğrusal Olmayan Otoregresif (NAR) ağını kullanmıştır. Kullanılan yöntem ve verilerin analizi neticesinde Doğrusal Olmayan Otoregresif ağıının tatmin edici sonuçlarla saatlik ışıınımı tahmin edebildiğı ve daha iyi tahmin üretebildiğı tespit edilmiştir(KA Baharin ve HA Rahman. 2013).

Erdil ve Arçaklıoğlu (2013), YSA modeli kullanılarak meteorolojik değişkenler

tahmin edilmiştir. Türkiye Meteoroloji Merkezi’den farklı ölçüm istasyonlarından alınmış rakım, boylam, aylık-günlük maksimum ve minimum nem, basınç ortalama güneşlenme süresi ile günlük minimum ve maksimum sıcaklık verileri kullanılarak, girdi olarak ele alınan ve günlük güneş radyasyonunu tahmin eden yapay sinir ağı modeli kullanılmıştır. Yapay sinir ağı modeli eğitilip test edildiğinde meteorolojik değerlerin tahmini gerçekleştirilmiş olup bunun neticesinde elde edilen test sonuçlarında R^2 değeri 0.997 ve ortalama yüzde hata 5.775 olarak bulunmuştur. Analiz sonuçlarına göre tahmini ve ölçülen değerler arasındaki farkın çok düşük olduğu tespit edilmiştir. Tahmin için sinir ağı modelleri meteorolojik değişkenlere başarıyla uygulanmıştır(Erdil ve Arcaklioglu, 2013).

Long ve arkadaşları (2014) güneşlenme süresi, güneş radyasyonu, rüzgar hızı, çiğ sıcaklığı, üretilen güç gibi parametrelere bağlı olarak günlük güneş enerjisi tahminini başta yapay sinir ağları(YSA) olmak üzere dört farklı yöntemle tahminleme analizi gerçekleştirilmiştir. Tahminde en iyi sonucu elde edebilecek parametreleri seçerken korelasyona bağlı parametre seçim metodu uygulanarak temel parametreler modellerde giriş olarak ele alınmıştır. Gerçekleştirilen analiz sonucunda YSA modelinin sonuçlarında R^2 değeri 0.909. RMSE değeri 59.57. MAPE %11.87 olarak bulunmuştur(Long, Zhang, & Su, 2014).

Şahan ve arkadaşları.(2015) Osmaniye ilinin günlük toplam ışıınımını tespit etmek için Osmaniye Korkut Ata Üniversitesi Merkez yerleşkesinde bulunan OKÜMERLAB (Osmaniye Korkut Ata Üniversitesi Merkezi Laboratuvarı) binasının (Enlem: 37°.04227, Boylam: 36°.22134) çatı katına yerleştirilen 8-48 Model Black And White Pyranometer ölçüm cihazı kullanılarak Mayıs 2013 ile Nisan 2014 tarihleri arasında dakikalık olarak milivolt(mV) cinsinden toplam ışıınım verileri almıştır. Yatay yüzeye gelen toplam global ışıınım bileşenini 1662322.88 W/m² olarak hesaplamıştır. Günlük toplam global güneş ışıınımının aylık ortalama değerleri sırasıyla 4755.43 W/m² olarak ölçmüş olup ve günlük ortalama global güneş ışıınımı 396.29 W/m² olarak bulmuştur. Analiz sonucunda ise en yüksek toplam ışıınım değerleri Haziran ayında 528.33W/m² olarak ölçülmüş en düşük toplam değerleri ise 201.23 W/m² olarak Aralık ayında ölçülmüş olup saatlik verileri günlük olarak aylık ölçülen toplam değerleri Devlet Meteoroloji Genel Müdürlüğü’nün web sayfasından almış olduğu sıcaklık değerleri ve güneşlenme süreleri ile karşılaştırılmıştır(Şahan, Tokat, & Okur, 2015).

Coşkun ve arkadaşları (2016) YSA yöntemi ile fotovoltaik(PV) panel yüzey sıcaklığını tahminini amaçlamıştır. YSA eğitim için, bağımsız değişken olarak güneş radyasyonu, dış sıcaklık ve rüzgar hızı değerleri yani girdi ve bağımlı yani çıktı değeri için de yüzey sıcaklığı verilerini kullanmıştır. Yapay sinir ağlarına dahil edilen veri setinin üçte ikisini eğitim üçte birini ise test için kullanmıştır. Leveberg-Marquardt (LM) algoritması yardımıyla ileri besleme yapay sinir ağları ile eğitilmiştir. İki tane geri yayılım (backpropagation) ağları bunlar ise Scaled Conjugate Gradient (SCG) Backpropagation ve Resilient Backpropagation (RB) YSA algoritması yardımı ile de analiz etmiştir ve analiz sonucunun performansları LM algoritmasının tahmini ile karşılaştırma yapılmıştır. Bu üç tip yapay sinir ağları algoritmalarının performansı karşılaştırılmıştır ve ortalama hata oranları %0.012177 ile %0.005962 aralığında elde edilmiştir. En iyi tahmine LM algoritması ile ulaşılmıştır. Fotovoltaik yüzey sıcaklığı tahmini konvansiyonel bağıntı metotları ile karşılaştırmış, karşılaştırma sonucuna ise YSA konvansiyonel bağıntı metotlarının daha iyi sonuç verdiği görülmüştür. Çalışma sonucunda ise PV yüzey sıcaklığını tahmininde yapay sinir ağlarını etkili bir şekilde kullanılabileceğini göstermiştir(Coskun, Koçyiğit, & Oktay, 2016).

Gala ve arkadaşları (2016) çalışmasında sayısal hava tahmini tarafından sağlanan 3 saatlik kümülatif güneş ışıınımı tahminlerini geliştirmek için Destek Vektör Regresyonunu (SVR). Gradient Boosted Regresyonunu (GBR). Rastgele Orman Regresyonunu (RFR). Eğim Artan Regresyon (EAR). Rastgele orman regresyon ve bu regresyonların yanında alt ölçekleri toplamak için hibrit metodu uygulanmıştır. Ayrıca, açık gökyüzü teorik ve deneysel radyasyon modellerine dayanan interpolasyonu kullanılarak üç saatlik tahmin verilerinden saatlik tahmin verileri elde edilmesi için çalışma yapılmıştır. Makine öğrenmesi metotlarının veya daha kapsamlı adı ile hibrit yapay zekâ sistemlerinin oldukça etki gösterdiği ve bundan dolayı güneş ışıının tahmini için uygun bir metot olduğunu kanısına varılmıştır(Gala, Fernández, Díaz, & Dorronsoro, 2016).

Li ve arkadaşları (2016) Avustralya Meteoroloji Bürosu tarafından oluşturulan veri seti kullanılarak makine öğrenimi metodolojilerinin uygulandığı çalışmalarında; Gizli Markov Modeli ve SVM regresyonuna dayalı kısa vadeli güneş ışıınımı tahmin algoritmalarını tanıtmaktadırlar. Bu metodolojilerin önemini göstermek için tekniklerin göreceli performansını analiz etmek için bir dizi deneysel değerlendirme sunulmuştur. Bu

değerlendirmeler için Hava Tahmin Platformu olan MATLAB arayüzü kullanılmıştır. Deneyisel sonuçların neticesinde, makine öğrenimine dayalı Gizli Markov (Hidden Markov Model) ve SVM regresyon(SVM regression) tahmin algoritmalarının, farklı hava koşulları altında gelecekteki 5-30 dakikalık güneş ışıınımını kesin olarak tahmin edebildiğini göstermişlerdi(Li, Ward, Tong, Collins, & Platt, 2016).

Okur (2016) Akdeniz bölgesine ait farklı coğrafi özelliği ve iklim koşullarını gösteren 14 yerleşme yeri verilerini kullanılarak güneş ışıınım şiddetini tahmin etmek için YSA yöntemini kullanmıştır. YSA'da ileri beslemeli yöntemi kullanmış olup yapılan çalışma sonucunda yatay düzleme gelen güneş enerjisinin belirlenmesinde YSA yöntemlerinin etkin olduğu görülmüştür(Okur, 2016).

Bou-Rabee ve arkadaşları (2017), yaptığı çalışmalarında. Kuveyt'te beş farklı bölgeden elde edilen verileri kullanarak günlük ortalama güneş radyasyonunu tahmin etmek için YSA modellerini kullanmışlardır. Kuveyt'teki günlük ortalama güneş radyasyonu için bir model tahmincisi geliştirilmiş ve YSA tahmin modeli. doğrusal olmayan verilerin analizi ile yapılmıştır. Model geliştirilirken eğitim/test verisi olarak beş farklı Kuveyt sitesindeki gerçek veriler kullanılmıştır. 2007-2010 arası verilerle eğitilen model. 2011 verileri ile test edilmiştir. Geliştirilen üç farklı YSA modeli içinden Levenberg-Marquardt algoritmasını kullanan model %85,6 MAPE değeri ile en başarılı sonucu verdiği tespit edilmiştir(Bou-Rabee, Sulaiman, Saleh, & Marafi, 2017).

Caballero ve arkadaşları (2018) İspanya, Almeria'daki operasyonel bir güneş enerjisi planındaki yüksek çözünürlüklü radyometrik ağdan bir yıl boyunca kaydedilen bir veri kümesine dayalı olarak normal güneş ışıınımını yüksek uzaysal ve zamansal çözünürlükle (5 dakika) tahmin etme problemini ele almışlardır. Bir önceki saatte elde edilen ışıınım değerlerinden sonraki birkaç dakikadaki ışıınımı tahmin etmek için bir teknik göstermeyi amaçlamaktadırlar. Uzun- Kısa Vadeli Bellek(LSTM) olarak bilinen. karmaşık kalıpları öğrenebilen ve zamansal serileri tahmin etmek için kullanılabilirliğini kanıtlamış bir tür tekrarlayan sinir ağı kullanılmıştır. Tahmin sonucunda zamansal seri çalışmalarında tipik olarak kullanılan diğer tahmin yöntemlerine göre makul bir gelişme gösterdiği tespit edilmiştir(Caballero, Zarzalejo, Otero, Piñuel, & Wilbert, 2018).

Altunkaynak ve Başakın (2018), makalelerinde Amerika'da bulunan Columbia Nehri'nin 1950-1960 yılları arasında ölçülmüş olan günlük akım değerleri işleme alınarak matematiksel model geliştirmeyi amaçlamışlardır. Matematiksel model için Uyarlamalı

Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi yöntemi (ANFIS), YSA ile Doğrusal Olmayan Otoregresif Model(NAR) ve ARIMA yöntemleri kullanılarak ve karşılaştırmaları yapılmıştır. Çalışmanın sonucunda ise en iyi matematik modelini oluşturan yöntem Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi yönteminin (ANFIS) NAR ve ARIMA tahmin modelinin YSA'nın NAR ve ARIMA modeline göre daha başarılı sonuç verdiği görülmüştür(Altunkaynak ve Başakin, 2018).

Sorkun (2018), akademik çalışmasında Fransız meteoroloji kuruluşu 1998 -2007 yılları arasındaki 87 600 güneş ışıınımı veriler kullanarak derin öğrenme yardımı ile zaman serisi tahminlemesi yapmıştır. Güneş radyasyonu verileri ile zaman serilerinden olan RNN modellerini uygulamış ve tek değişkenli ve çok değişkenli modeller için ayrı ayrı analizler yapılmıştır. Tek katmanlı değişkenli modelde, GRU ve LSTM modelleri oluşturmuş ve derinliğin etkisi araştırılır ve yüksek parametreler ayarlanır. Sonuçlara olarak LSTM ve GRU modelleri analiz sonuçları aynı çıkmıştır. LSTM ve GRU modellerinin. Recurrent Neural Network (RNN) modelinden daha başarılı olduğu sonucuna varılmıştır. İki katmanlı değişkenlerde ise tek katmanlı değişken analizlerinden daha iyi sonuç vermiştir. En iyi yapı bulunduktan sonra modelin mevsimsel performansı araştırılmış ve diğer makine öğrenme yöntemleriyle karşılaştırılmıştır. Mevsimsel deneysel sonuçlara göre. iki katmanlı bir GRU modeli ve rastgele orman modeli kullanılarak yeni bir hibrit model önerilmiştir. Bu hibrit model. LSTM ve GRU modellerine kıyasla daha iyi performans göstermiştir. Çok değişkenli deneylerin sonuçlarına göre sıcaklık ve nebulozite parametreleri modelin performansını önemli ölçüde artırmıştır. Diğer parametreler çok az katkıda bulunur. Küresel Güneş Radyasyonunu kullanarak en iyi performansı elde etmiştir(Sorkun, 2018).

Can ve Gerşil makale çalışmalarında 2017 yılına ait Manisa Pamuk Borsa'sından alınan veriler WEKA programı ile veri madenciliği ile 2018 yılına ait fiyatlar tahmin edilmeye çalışılmıştır. Çalışmada zaman serileri ve YSA ile tahminleme yapılarak karşılaştırılmıştır. Analiz sonucu doğrultusunda bulunan veri için fiyat tahmini yapıldığında YSA tahmin yönteminden daha başarılı sonuçlar verdiği görülmüştü(Can ve Gerşil, 2018).

Emrahoğlu ve Yeğingil (2019), Çukurova Üniversitesi Uzay Bilimleri ve Güneş Enerjisi Uygulama ve Araştırma Merkez'inde (UZAYMER) piranometre ile 1978-1982 yılları arasında alınan anlık veriler ile 2017 yılında alınan verilerin karşılaştırmalı olarak

analizi yapılmıştır. 1978-1982 yılları arasında Adana’da yıllık ortalama güneş enerjisi değeri 5745,1 MJ/m² ve ortalama günlük toplam ışıyım 15.74 MJ/m² gün olarak belirlenmiş olup en az enerji Ocak ayında 6.84 MJ/m² gün, en fazla güneş enerjisi ise 25.42 MJ/m² gün ile Haziran ayında olduğu tespit edilmiştir. 2017’de alınan verilerin sonucunda ise yıllık ortalama günlük güneş enerjisi 17.75 MJ/m² gün, yıllık ortalama güneş enerjisi ise 6479,99 MJ/m² olarak hesaplanmıştır. En fazla güneş enerjisi 29.25 MJ/m² gün ile Temmuz, en az ise 6.24 MJ/m² gün aralık ayı olarak belirlenmiştir. 1978-1982 ve 2017 verilerinden. Bulutsuzluk indeksi de belirlenerek karşılaştırılmıştır. Bu sonuca göre $K_t < 0.34$ değeri için bölgenin bulutlu. $0.34 \leq K_t \leq 0.64$ değerleri arasında ise kısmen bulutlu. $K_t > 0.64$ değeri için ise havanın açık olduğu kabul edilmiştir. 1978-1982 dönemi için en bulutlu ay Şubat en açık ay ise Eylül ve 2017 verilerine göre de en bulutlu ay Şubat, en açık ay ise Temmuz ve Ekim olarak belirlenmiştir (Emrahoğlu ve Yeğingil, 2019).

Fan ve arkadaşları (2019) küresel güneş radyasyonu tahmininde ele alınan ampirik ve makine öğrenmesi metotlarının detaylı bir literatür çalışmasını yapıp kısaca özetlemiştir. Bunun yanı sıra Çin’in farklı coğrafi bölgelerinde küresel güneş ışıyımı tahmininde 12 ampirik ve 12 makine öğrenmesi metodu kullanılmış ve çıkan performansları karşılaştırmıştır. Sonuçlar, makine öğrenmesi modellerinin (RMSE: 2.055-2.751 MJm⁻² d⁻¹; R²: 0.839- 0.936) genellikle ampirik modellerden (RMSE: 2.118–3.540 MJm⁻² d⁻¹; R²: 0.834-0.935) daha iyi performans gösterdiğini tespit edilmiştir. Tahmin doğruluğu ve hesaplama maliyetleri dikkate alındığında, çalışmada en uygun yöntemin ANFIS olduğu sonucuna ulaşılmıştır (Fan et al., 2019).

Ghofrani ve arkadaşları (2019) farklı yöntem ve makine öğrenme tekniklerinin güneş ışıyımı tahmini için kullanıldığını gösteren detaylı bir literatür çalışması yapmışlardır. Yapmış oldukları çalışmalar sonucunda, veri kümeleme analizi veya sınıflandırma analizi ile düzensiz olan güneş ışıyımı, zaman serilerinde metotlarından daha çok yapay sinir ağları için daha iyi eğittiğini ve tahmin doğruluğunu daha iyi yansıttığı varmışlardır. Bunun yanı sıra, çoklu örüntü tanıma metotlarını ve makine öğrenme metotlarını kullanan hibrit tahmin metotları hesaplama karmaşıklıkları, bunları çevrimiçi tahminler veya çok kısa zaman tahminleri için yeterli olmadığını tespit etmişlerdir (Ghofrani, Azimi, & Youshi, 2019).

Uğuz ve arkadaşları (2019), Türkiye’de 125 farklı bölge için kurulması planlanan PV

santrallerinin üreteceği elektrik gücünün, makine öğrenmesi yöntemleriyle modellemesi ve tahmin edilmesini amaçlamışlardır. Amaçlarına yönelik PV sistemler için güneş ışıınımı tahmin edilmesinde için YSA, Çoklu Doğrusal Regresyon (ÇDR) ve k-En Yakın Komşu Regresyon (k-EYKR) makine öğrenimi yöntemleri ile analiz etmişlerdir. Bu yöntemlerin performansını analiz etmek amacıyla bazı deneysel değerlendirmeler yapılmıştır. Değerlendirmeler için veri seti, Numpy, Pandas, Scipy gibi temel python programlarının yanında makine öğrenmesi yöntemleri için geliştirilmiş olan scikit-learn programında analiz edilmiştir. Analiz verilerin %30'u makine öğrenme metotları kullanılarak oluşturulan modelleri analiz ederken, verilerin %70'i modelleri eğitmek için kullanmıştır. YSA modellerinin eğitim aşamasında en yüksek R^2 0.959 değeri veririrken, en düşük hata değerlerinin MAE. MSE ve MedAe için sırasıyla 0.039. 0.002 ve 0.031 değerleri görülmüştür. Üç oluşturulan model arasında en iyi performansa YSA modeli ile ulaşılmıştır. Deneysel sonuçlar, girdi olarak el alınmış olup yedi tane veri bağımsız değişkenin, makine öğrenmesine dayalı tahmin algoritmalarının test edilmesiyle PV tarafından arz edilen elektrik gücünü tahmin edilebileceği sonucuna varılmıştır(Uğuz, Oral, & Çağlayan, 2019)(Uğuz et al., 2019).

Kaya (2020) yaptığı tez çalışmasında, kısa dönemli güneş ışıınım şiddeti tahmininde güçlü bir araç olan YSA ile Dalgacık Ayırıştırma Yöntemi-Wavelet Decomposition(WD) ve Görgül Kip Ayırışımı-Emprical Mode Decomposition(EMD) yöntemlerini bir arada kullanılarak hibrit modeller çalışmıştır. Hibrit modelde Bilecik iline ait aylık güneş ışıınım şiddeti verileri WD ve EMD yöntemleri ile alt sinyal bileşenlerine ayrıştırılmış olup her bir seviye için geçmiş zaman verileri ile birlikte İleri Beslemeli Ağ-Feed Forward Neural Network(FFNN) modeliyle eğitilerek sonuçları elde edilmiştir. Oluşturulan her bir hibrit ağ yapısının test performans sonuçları, yalnızca YSA kullanılarak elde edilen çıktılarla karşılaştırılmıştır. Aylık baz alınan çalışmada elde edilen sonuçların hata performans kriterleri RMSE metriğine bağlı olarak 81.28 bulunmuştur ve sadece yapay sinir ağı modelinin kullanıldığı çalışmanın hata performans kriterleri RMSE metriğine bağlı olarak 84.44 bulunmuştur. Yapılan çalışma sonucunda her iki ay içinde görgül kip ayrışımı ve yapay sinir ağlarının birlikte kullanıldığı hibrit (FFNN_EMD) çalışmanın daha iyi sonuç verdiği tespit edilmiştir(Kaya, 2020).

İçel (2019) çalışmasında ele alınan üç pilot bölge (Adıyaman-Malatya-Şanlıurfa) ele alınarak fotovoltaiik panellerden bir yıl içerisinde aralıklı olarak panele gelen güneş

ışınımını analiz etmiştir ve elde edilen veriler YSA modeli ile üretilerek güç tahmini analizini yapmıştır. Sonucunda ise elde edilen veriler bölgelerde fotovoltaik panellerden ölçülen enerji değeri oldukça iyi tahmin edildiği sonucuna ulaşılmıştır(İçel, 2019).

Gabralı (2019) yılına ait İstanbul Büyükçekmece ilçesi Eskice bölgesine ait meteorolojik verileri (rüzgar şiddeti ve güneş radyasyonu) kullanarak mevsimsel analiz yapılmıştır. Analiz yöntemlerinden MS-Excel ve SPSS paket programı ile Çoklu Lineer Regresyonu (ÇLR) ve MATLAB programı yardımı ile de YSA kullanılmıştır. YSA tahminleme yönteminin daha iyi sonuç elde etmek için verilere aylık olarak dalgacık dönüşümü ön işlemi yapılmış olup. Dalgacık Yapay Sinir Ağı (D-YSA) hibrit modeli geliştirmiştir. Çıkan sonuçlarda ise YSA tahmin sonucu çoklu lineer regresyon sonucuna göre daha iyi sonuç vermiştir. YSA tahmin sonucuna göre ise D-YSA daha başarılı ve gerçeğe uygun sonuç vermiştir(Gabralı, 2019) .

Arslan ve arkadaşları (2019) çalışmalarında Nisan 2017 – Mart 2018 yılları arasında Mersin iline ait günlük güneş ışıınımı verileri için bağıl nem, rüzgar hızı ve sıcaklık değişkenlerini kullanmıştır. Bağımsız değişkenlerin bağımlı değişkeni açıklama oranı yani belirlilik katsayısı(R^2) en iyi açıklayan model 0.83 ile ZHM modeli olmuştur. İkinci model olarak 0.71 ile YSA modeli olmuştur(Arslan, Bayhan, ve Yaman, 2019)

Şahin (2019),çalışmasında Sivas ilinin (Divriği, Gemerek, Kangal Sivas Merkez ve Su Şehri) beş farklı ilçesine ait coğrafi ve meteorolojik verileri kullanmıştır. Güneşlenme süresi, enlem boylam, hava sıcaklığı, rüzgar hızı, yükseklik gibi değişkenler kullanılarak MATLAB programı yardımı ile rüzgar ve güneş ışıınımını tahminlemesi yapılmıştır. Güneş ışıınımı için 1986-2000 (2010-2016 Divriği için) yıllarındaki veriler ve rüzgar hızı içinde 2000-2017 yılları arasındaki aylık ortalama rüzgar hızları verileri kullanılmıştır. Belirlilik katsayısı(R^2) (sırası ile ise 0.984 ile 0.994 değerler çıkmıştır. YSA yönteminin Sivas il ve ilçelerinin güneş ışıınımı ve rüzgar hızı tahmininde etkili bir yöntem olduğu sonucuna varılmıştır(Şahin, 2019).

Kaya (2019) çalışmasında 1961-2009 yılları arasında Türkiye’de seçilmiş 29 konumun (il ve bazı ilçelerinin) güneşlenme saatini, sıcaklık değişkenlerini, aylık ortalama ve günlük ortalama güneş ışıınım verilerini Meteonorm yazılımından elde etmiştir. Global ışıınım verilerinin tahmini için Genetik Algoritma (GA) ve YSA tahminleme modellerini kullanmıştır. GA tek amaçlı optimisasyon için tasarlanmıştır Türkiye’deki konum ile Dünyadaki 5 konumu kullanarak YSA yöntemi ile test etmiştir.

Çalışmanın sonucunda ise YSA'nın MAPE değeri GA değerinden daha iyi sonuç verdiği için YSA modelinin belli bir konumdaki eğitim ve test verilerini kullanarak GA sonucunu iyileştirme yoluna gidilmiştir(Kaya, 2019).

Erenler (2019) çalışmasında otomasyona dayalı seri üretim yapan fabrikalarda üretim esnasında oluşacak kalite kayıplarının kontrolünü sağlamak için 650 günlük 1950 vardiya sistemine ait 1950 palet üzerindeki üretimin sağlanması ile veri toplanmıştır. Bu çalışmadaki amacı; kalite kontrolü üzerindeki insan etkisini tahmin edip öneriler sunmaktır. Tahminleme yöntemi ise MS Excel programına bütünleşmiş edilen K-Nearest Neighbor (KNN) ve YSA ile tahminleme yapılmıştır. Her iki yöntemin sonucu çok iyi çıkmıştır YSA'da 99.99 hata terimi ulaşılırken, KNN ise 99.98 çıkmıştır. Analiz sonucuna göre de KNN ve YSA metotları ile talep, hammadde ihtiyacı, arıza zamanı gibi üreticiler için sıfır hata kabul edilen konularda tahminleme yapılabilmesi olabildiğince hızlı ve kolay bir şekilde hayatımıza geçirileceği sonucuna ulaşmıştır(Erenler, 2019).

Çelik (2019) araştırmasında TR33 bölgesinde (Kütahya. Afyon. Uşak. Manisa) hızla büyüyen ve 30 üzerinde kolları olan bir zincir perakende satış mağazasında veri programı yardımı ile tüketicilerin 2016-2019 yıllarına ait alışveriş kayıtlarından sağlanmıştır. Araştırmanın amacı parkende satış mağazalarında alışveriş yapan müşterilerin davranışlarının tahmin modelini oluşturmaktır. Çalışmaya dâhil edilen veriler ise 489 tüketiciye ait 26.543 adet alışveriş kaydı ve 40 adet ürün grubundan 45.650 adet satın alınan ürün bulunmaktadır ve örneklem olarak da 3.982 farklı ürün araştırmaya dâhil edilmiştir. Kümeleme analizi, sınıflama analizi ve lojistik regresyon analizi SPSS22 paket programı ve Visual Basic yardımı ile yapılmıştır. Birliktelik kuralı ve tahminleme modelinin yapılması için MATLAB programı kullanmıştır. Tahminleme YSA ve Lojistik Regresyon (LR)yöntemleri kullanılarak yapılan araştırma sonuçları karşılaştırılmıştır. YSA en az 15 iterasyon ile ortalama %99,9621'lik bir doğru tahminlemeye ulaşırken, lojistik regresyon analizi ise en az 20 iterasyon ile ortalama %89,8305'luk bir doğru tahminleme elde edilmiştir. Çıkan analiz sonuçlarına göre, YSA yöntemi LR yöntemine göre daha iyi sonuç verdiğini yorumu yapılmıştır(Çelik, 2019)

İpek (2019) çalışmasında. Endüstri 4.0 teknolojisini kullanılan bir üretim hattından sensör yardımı ile 15 dakika da bir elde edilen basınç, alev, nem, sıcaklık, hareket, yüzey sıcaklığı verilerinin her biri saatlik veriye dönüştürülerek basınç (221), alev (221), nem (116), sıcaklık (44), hareket (183) ve yüzey sıcaklığı (170) yeni bir veri

seti oluşturulmuştur. Oluşturulan her veri seti eğitim ve test olmak üzere basit rassal ayırım yöntemi ile eğitim ve test veri seti olarak iki sınıfa ayrılmıştır. Her veri setinin %90'ı eğitim veri seti, %10'u ise test veri seti olarak kullanılmıştır. Oluşturulan modeller bu eğitilen verilere göre sistem yapısını öğrenecek ve daha sonra test veri setleri ile öğrendikleri yapının doğruluğunu karşılaştıracaktır. Yöntem olarak Zaman Serilerinde RMSE ve MAPE yöntemlerine bakılırken, MATLAB programında ise ANFIS ve Box-Jenkins yöntemi kullanılarak çıkan sonuçları karşılaştırmıştır. Endüstri 4.0 teknolojisi kullanılan bir işletmenin üretim hattı da oluşturulan zaman serisi verileri analiz edilmiş olup ANFIS ve ARIMA modelleri karşılaştırma sonucunda ANFIS modelinin daha verimli olduğu gözlenmiştir (İpek, 2019).

Eyvazon (2019), çalışmasında 2013-2018 yılları arasındaki güneş radyasyon verilerini kullanarak güneş enerji potansiyelini tahmin etmek istemiştir. Verileri ise Ankara Bölge İstasyonu'nun ölçümlerinden elde edilen verileri Meteoroloji Genel Müdürlüğünden (MGM) temin etmiştir. Tahminleme teknikleri olarak da en çok kullanılan YSA yöntemi kullanmıştır ve sonucunun iyi çıkması için eksik verileri tamamlayıp ön işlem olarak da 0-1 arası Min-Max yöntemi ile verileri işlemiştir. Verileri input(girdi) olarak 2013-2017 yıllarındaki verileri işleme alıp 2018 yılındaki verileri ise output(çıkı) olarak kullanmıştır. Yapılan üç algoritma LM, Bayesian Regularization(BR), Ölçekli Eşlenik Eğitim(ÖEE) çıkan sonuçlar karşılaştırılmıştır. Yapılan karşılaştırma sonucunda ise LM algoritması MSE=1.111. MAE=0.108 sonuçları ile en iyi tahminleme sonucunu vermiştir. Yorum olarak ise özellikle kısa dönem günlük enerji potansiyeli tahminleme araştırmalarında YSA modellerinden olan LM iyi sonuç verdiği başarı oranının yüksek olduğu görülmüştür (Eyvazov, 2019).

Gabralı ve Aslan (2020), yaptığı çalışmada ÇLR ve YSA kullanılarak İstanbul Büyükçekmece İlçesi Eskice Bölgesine ait 2016 yılı meteorolojik verileri kullanarak güneş radyasyonu için ileriye yönelik bir tahmin çalışması yapılmıştır. Modelleme için kullanılan tüm modeller karşılaştırılarak istatistiksel olarak yorumlanmıştır. Sonuçlar neticesinde yapılan güneş radyasyonu tahmin çalışmasında YSA modellerinin çoklu lineer regresyon modellerine göre daha başarılı olduğu tespit edilmiştir. Mevsimsel olarak güneş radyasyonu için en başarılı tahmin haziran ayında elde edilmiştir. En uygun başarımın elde edildiği yapay sinir ağı modeli ile güneş radyasyonu için RMSE ve MAPE değerleri sırasıyla 0.912, %48,5, %28.21 olarak bulunmuştur. YSA modelleri

ÇLR modellerine göre güneş radyasyonu tahmininde Haziran ve Eylül aylarında diğer aylara göre daha başarılı olmuştur(Gabralı ve Aslan, 2020).

Turaç (2020), çalışmasında 2003-2019 yılına ait gerçekleşen aylık ithalat rakamları (Bin ABD doları cinsinden), tüketici fiyat endeksi değişim oranı (TÜFE), gerçek dolar kuru, bir önceki ayın ihracat miktarı (ABD Doları), altın ons ve gram değeri, gümüş değeri, imalat sanayi gayrisafi yurt içi hasıla, toplam sanayi endeksi, imalat sanayi endeksi, Brent petrol fiyatı, imalat sanayi kapasite kullanım oranı ve işgücü maliyet endeksi bağımlı değişken olarak kullanmıştır. Yapılan modelin tahmini için ise YSA ve Zaman Serileri yöntemi kullanmış olup çıkan sonuca göre karşılaştırmasını yapmıştır. YSA da verilerin %80 eğitim için kullanırken %20'sini ise verileri test etmek için kullanmıştır. Analiz sonucu olarak da R^2 belirlilik katsayısına göre YSA'da eğitim için 0.81 test için ise 0.19 bulunmuş olup zaman serilerine göre en iyi sonucu vermiştir(Turaç, 2020).

Kır ve Gürdal (2020) makale çalışmasında Antalya ilinde kayıt yapılan 1933-2018 yılları arasında yıllık ve aylık olarak elde edilen verileri kullanmışlardır. Verileri aylık olarak 1032 ve yıllık olarak ise 86 adet veri ile iki bölümde modellemesini yapmak istemiştir. Analizlerde zaman seri yöntemi ile ARIMA, MSE belirlilik katsayısı R^2 'sine standart sapmasına ve varyans gibi istatistik değerler incelenmiştir. Sonuç olarak da uygulanan stokastik yöntemlere göre, yıllık yağış kayıtlarının önemli bir korelasyona sahip olmadığı ve beyaz gürültü serisi gibi davrandığı ortaya çıkmıştır. Aylık verilerin analiz sonucu ise zaman serisinin sezonluk olarak değiştiği kanısına varmıştır(Kır ve Gürdal, 2020).

İKİNCİ BÖLÜM


Bu bölümde yapay zekanın genel tanımı kullanım alanları ve yapay zekanın alt dallarından YSA ve MÖ açıklanacaktır.

2.1. TAHMİNLEME TEKNİKLERİ

Bu bölüm de tahminleme tekniklerinden olan Yapay Zeka(YZ) yöntemlerinden Yapay Sinir Ağları(YSA) ve Makine Öğrenmesi(MÖ) yöntemleri açıklanmıştır.

2.1.1. Yapay Zeka

YZ bir bilgisayarın ya da bilgisayar sistemine bağlı bir robotun, insanoğluna benzer biçimde bazı hareketleri ve eylemleri yerine getirme özelliğini ortaya koyan bir keşiftir. Diğer bir tanım ile YZ; bir bilgisayarın ya da bilgisayar destekli bir makinenin, genellikle insana özgü nitelikler; çözüm yolu bulma, anlama, bir anlam çıkartma, genelleme ve geçmişteki deneyimlerinden öğrenme gibi yüksek mantık süreçlere ilişkin görevleri yerine getirme yeteneğidir(İşler ve Kılıç, 2021).



Şekil 7. Yapay Zeka Tanımı

Kaynak:(Kavas, 2019)

YZ belki de bilgisayar biliminin en eski alanıdır. Gerçek dünyadaki problem çözme ve insanlar gibi öğrenen ve düşünen sistemler oluşturmak için bilişsel işlevleri taklit etmenin tüm yönleriyle ilgilenen geniş bir alana sahiptir. Bu nedenle, genellikle makine zekası olarak adlandırılır. YZ artık MÖ' deki pratik başarılarından dolayı büyük ilgi görmektedir. YZ da her zaman açıklana bilirlikle güçlü bir bağlantı vardır ve McCarthy tarafından 1958'de "sağduyulu bir program" olarak önerilen Advice Taker'dır. Bu muhtemelen YZ'nın anahtarı olarak sağduyulu akıl yürütme yeteneklerini ilk kez önerilmektedir. Son araştırmalar, YZ sistemlerinin yalnızca örüntü tanıma problemlerini çözmek yerine,

dünyanın açıklama ve anlamayı destekleyen nedensel modellerini oluşturabilmesi gerektiğini giderek daha fazla vurgulamaktadır(Holzinger, Langs, Denk, Zatloukal, & Müller, 2019).

2.1.1.1. Yapay Zekanın Tarihçesi

İnsanoğlu var oluşundan itibaren insan zihninin problem çözme ve karar verme yeteneklerini taklit etmek ve bu doğrultuda veri toplama, veri depolama alanında çalışmalar yaparak makinelerden ve bilgisayarlardan yararlanma ihtiyacı duymuştur. YZ kavramının doğuşu 1950 yılında yayınlanan “Hesaplama Makineleri ve İstihbarat” adlı çalışmayla Alan Turing tarafından gündeme getirildi. Turing’in “Makineler düşünülebilir mi?” sorusu ile “Turing Testi” olarak bilinen bir insan sorgulayıcının bir bilgisayar ile insan metninin ayırt etmeye çalışacağı bir test olarak karşımıza çıkmıştır. Bu test YZ tarihinin önemli bir parçası olmaya devam etmektedir. YZ’ nin hedef ve tanımında iki yaklaşım hedeflenmektedir: insan yaklaşımı ve ideal yaklaşımdır.

İdeal Yaklaşımı:

- Mantıklı düşünen sistemler
- Mantıksal davranan sistemler

İnsan Yaklaşımı:

- İnsan gibi düşünen sistemler
- İnsan gibi davranan sistemler

YZ en basit haliyle, insan problemlerini bilgisayar bilimi ile sağlam veri kümelerini birleştiren bir alandır. YZ 1950–1970’lerde nöral ağlar olarak, 1980– 2010’larda MÖ olarak, günümüzde ise Derin Öğrenme(DÖ) olarak karşımıza çıkmaktadır(IBM, 2020).

Tablo 2. Yapay Zeka Kronolojik Sıralaması

Olay	Açıklama
Bilgisayar ve Zeka (1950)	Alan Turing, makinelerin düşünebilmesinin mümkün olup olmayacağını sorguladığı makalesini paylaşması, bir dönüm noktası yarattı.
Ben. Robot (1950)	Isaac Asimov, etkileri büyük olmuş “Ben. Robot” adlı bilim kurgu romanını yayınladı.
Yapay Zeka ve Oyun (1951)	Manchester Üniversitesi’ne ait Ferranti 1 makinesini kullanan Christopher Strachey dama programı, Dietrich Prinz ise satranç programı yazdı.
John McCarthy (1955)	1956 yılındaki Dartmouth Konferansı için 1955 yılında McCarthy, Yapay Zeka terimini ortaya koymuştur.
Perceptron (1957)	1957 yılında bilgisayar bilimci ve psikolog Frank Rosenblatt, canlı sinir hücrelerinden esinlendiği Perceptron (algılayıcı) modelini matematiksel olarak ortaya koymuştur.
Unimation (1962)	Unimation, endüstriyel anlamda 1962 yılında Amerika’da kurulan ilk robot şirketidir.
Marvin Minsky (1967)	Marvin Minsky, “Bir kuşak içinde ‘yapay zeka’ oluşturma problemi çözülmüş olacak” tezini 1967’de ortaya atmıştır
XOR Problemi (1969)	Martin Minsky ve Seymour Papert, “Algılayıcılar: Hesaplamalı Geometriye Giriş” kitabını yazmışlardır. XOR problemine değinmişlerdir.
Cylons (1973)	Orijinal “Battlestar Galactica” bilim kurgu dizisinde savaşçı robotlar Cylonlar tanıtıldı
AAAI (1980)	1979 yılında kurulan Amerikan Yapay Zeka Derneği (AAAI), ilk ulusal konferansını 1980 yılında Stanford’da düzenledi
Deep Blue. Kasparov (1997)	IBM tarafından geliştirilen Deep Blue, 1997 yılında Garry Kasparov ile girdiği satranç karşılaşmasını kazandı.
Watson ve Jeopardy! (2011)	IBM’in Watson bilgisayarı, televizyon yarışması “Jeopardy!” şampiyonları Rutter ve Jennings’i yendi.
Apple Siri (2011)	Apple şirketinin 2011 yılında geliştirdiği Siri; telefon, tablet veya bilgisayar kullanıcılarının sorularını yanıtlamak, tavsiyelerde bulunmak ve web hizmetindeki eylemleri yerine getirmek için tasarlanmış bir akıllı kişisel asistandır.
GPU Çağı (2012)	GPU odaklı bir sistem. ImageNet veri tabanında en iyi hata oranını 2012 yılında yarıya indirerek birinci olmuştur.
Amazon Alexa	Yapay zeka tabanlı ve bulut teknolojisini kullanan sanal bir asistan olan Amazon Alexa, 2014 yılında hizmete girdi.

(2014)	
AlphaGO (2016)	Google DeepMind tarafından geliştirilen AlphaGO, 2016 senesinde Lee Sedol ile karşılaştığı go maçını 4-1 kazanmıştır.
Asilomar (2017)	Asilomar Conference on Beneficial AI (Faydalı Yapay Zeka), Future of Life Institute tarafından, 2017 yılında Kaliforniya'daki Asimolar Konferans Alanı'nda düzenlendi.
Bert (2018)	Google, dönüştürücü ağ tabanlı doğal dil işleme modeli BERT'i yayınladı. AlphaZero: Deepmind AlphaZero, sadece kendi kendine oynayarak kısa sürede dünyanın en iyi satranç oyuncusu oldu.
OpenAI (2019)	1.5 milyar parametrelili GPT-2, OpenAI tarafından yayınlandı.
GPT-3 (175 Milyar Parametre) (2020)	Alphafold: 50 yıldır üzerinde çalışılan protein katlanma probleminin çözümünde yapay zeka kullanılarak büyük bir adım atıldı.
DALL-E (2021)	Yazıyla tarif edilen resimleri üretebilme yeteneği olan DALL-E adlı çalışma OpenAI tarafından yayınlandı.

YZ 1950 - 2021 yılları arasında nasıl bir değişim ve gelişim gösterdiği Tablo 2' de kronolojik olarak açıklanmıştır(Kıymaz, 2020).

2.1.1.2. Yapay Zekanın Kullanım Alanları

Yapay zeka geçmişten günümüze her alanda kullanılmaktadır. Yapay zekanın başlıca kullanım alanları:



Şekil 8: YSA'nın Kullanım Alanları

Kaynak:(Kavas, 2019)

Kısaca YZ'nin kullanım alanlarını sıralayacak ve tanımlayacak olursak geçmişte, günümüzde ve gelecek yaşam süremizde tahmin edebileceğimiz her alanda kullanılmaktadır ve kullanılacaktır.(Kavas, 2019)


2.1.2. Yapay Sinir Ağı (YSA) Teknikleri

YZ, insan beyninin benzerini bir makine içerisinde tasarlamak ve bu makinenin “akıl yürütme, bilgi sunumu, planlama, öğrenme, algılama, hareket edebilme ve manipüle etme becerisini” sağlama olarak tanımlayabiliriz. YZ araştırmaları Robotik ve Makine öğrenmesi olmak üzere iki ana alt alana bölünebilir. Robotik; tasarım, yapım, işletme ve robot kullanımı ile ilgilenir. MÖ, bilgisayar sistemlerine akıl yürütme, bilgi sunum, planlama ve öğrenme gibi işlevleri sağlamak için istatistiksel teknikleri kullanan

bir bilgisayar bilimi alanıdır.

YSA insan beyninin en temel özelliği olan öğrenme fonksiyonunu oluşturan bilgisayar sistemleridir. YSA veya bağlantı sistemi olarak da bilinen hayvan ve insan beyinlerindeki oluşturan biyolojik sinir ağlarından örnek alınarak geliştirilmiş bilgisayar ortamına uygulanmış yapay bir sistemdir.

Sinir hücresi veya nöron merkezi sinir sisteminin ana işlem odağıdır. Nöronların insan beyninde 10 milyardan fazla olduğu bilim insanlarınca söylenmektedir. Ağaç dallarına benzeyen ince yollar ile yani diğer adı dendritler olan sinir hücreleri dışardan aldığı bilgileri hücre gövdesine (soma) iletir. Elektriksel uyarı dendrite art arda dizili nöronlar ve aralarındaki sinapslardan geçerek ulaşır. Akson adı verilen yapılar dendritlere göre bilgiyi hücreden dışarıya taşıyan daha uzun bir yoldur. Aksonların ince yollara ayrılır ve bu ayrılan yollar da böylece diğer hücreler için dendritleri oluşturur(Kavas, 2019).



Şekil 9. Yapay Sinir Ağının Yapısı (Nöron)

- **Nöron:** Merkezi sinir sistemindeki bilgileri işleyen en temel yapıdır. Bilgiyi işler ve iletir.
- **Soma:** Hücre gövdesi
- **Dendrit (Alıcılar):** Nöronun sinyali algıladığı yer, hücreye bilgi götürür. Genellikle kısa ve üzerinde dalları olan uzantılardır.
- **Akson (İletken Lif):** Hücreden gelen uyarıları dışarı iletir. Kısa veya uzun olabilmektedirler. Eğer uzun ise ranvier boğumu sayısı daha fazladır.
- **Schwann Hücresi:** Miyelin kılıfı oluşturur.
- **Miyelin Kılıfı (Yağ Hücresi Tabakası):** Aksonun etrafındaki yalıtkan maddedir.


- **Ranvier Boğumu:** Miyelin kılıfının aralarındaki boşluklardır.
- **Sinaps:** Bir akson terminalinin hedef hücreye dokunacak kadar yaklaştığı yere denir(URL3, 2018)

Girilmiş olan veriler ağırlıklarla çarpılarak tüm veriler toplanır ve daha sonra önyargı eklenir bunun sonucunda ise net yargı elde edilir. Net girdi aktivasyon fonksiyonundan geçirilir ve bir veri çıktısı elde edilmiş olur.

2.1.2.1. Yapay Sinir Ağının Yapısı

YSA, birçok hücreden meydana gelir ve bu hücreler karmaşık şekilde bağlı çok sayıda işlem öğelerinden oluşmaktadır ve paralel işlem yapmaktadır. Yapay nöronlar aralarında bağlantı kurarak ağı meydana getirirler. İnsan beyinde öğrenme işlemi aksonlar sayesinde gerçekleşir. İnsan beyni yeni aksonlar üreterek; aksonları uyararak veya mevcut aksonların güçlerini değiştirerek öğrenir(Ataseven, 2013)

İnsan hücreleri gibi çalışan yapay sinir ağlarının da proses denilen nöronları bulunmaktadır. Bu proseslerin de beş ana ögesi vardır. Bu ögeler Şekil 10'da görülmektedir.



Şekil 10. Temel YSA Hücresinin Matematiksel Gösterimi

- **Girdiler (A_1, A_2, A_3):** Dışardan yapay sinir ağına öğrenmesi için aktarılan bilgilerdir.
- **Ağırlık (W_1, W_2, W_3):** Dışardan gelen bilgiler ile belirlenen bir değerin (ağırlık) çarpılması veya değerin sıfırla da çarpılmasıdır. Burada ağırlık değeri ne kadar yüksek ise değer o kadar iyi olduğu anlamına gelmez. Örneğin ağırlık sıfırdır ama veri çok önemli bir veridir.
- **Toplam Fonksiyonu (Birleştirme Fonksiyonu):** Bu fonksiyon girdilerden gelen bilgiyi toplar ve hesaplanmasını sağlar. Hesaplamaları yapmak için farklı

fonksiyonlardan yararlanılır. En çok kullanılanı ağırlık toplamıdır ve gelen girdi bilgileri öz ağırlığı ile çarpılarak toplanır. Bu işlemler sonucunda ise ağıla gelen net girdi bulunur. Toplam fonksiyonunda altı değişik model kullanılır ve aşağıdaki Tablo 3’de yer almaktadır(Kurt, 2017).

Tablo 3. YSA’da Bazı Toplama Fonksiyonlar

Toplam: NET: $\sum_{i=1}^N X_i * W_i$	Net girdi bulunurken belirlenen ağırlık değeri ile çarpılıp çıkan değerler birbiri ile toplanır.
Çarpım: NET: $\prod_{i=1}^N X_i * W_i$	Net girdi bulunurken belirlenen ağırlık değeri ile çarpılıp çıkan değerler yine birbiri ile çarpılır.
Minimum: NET=Min($X_i * W_i$)	Girdi için kullanılan n adet gözlem değerleri ağırlıklar ile çarpılıp çıkan sonuçlar arasından en küçük değeri minimum değer olarak ele alınır.
Maximum: NET=Max($X_i * W_i$)	Girdi için kullanılan n adet gözlem değerleri ağırlıklar ile çarpılıp çıkan sonuçlar arasından en büyük değeri maximum değer olarak ele alınır.
Çoğunluk: NET: $\sum_{i=1}^N \text{Sgn}(X_i * W_i)$	Girdi için kullanılan n adet gözlem değerleri ağırlıklar ile çarpılıp çıkan sonuçlar arasından negatif ve pozitif olanların sayısı belirlenir. Büyük olarak çıkan sayı hücrenin net girdisidir.
Kümülatif Toplam: NET=Net(eski)+ $\sum_{i=1}^N X_i * W_i$	Girdi olarak ele alınan veriler ağırlık ile toplanır ve daha sonra ilk hücreye gelen veri yeni çıkan veriye eklenerek hücrenin net olarak girdisi hesaplanır.


Kaynak: (Kurt, 2017)

Yukarda Tablo 3’ te de belirtildiği gibi aktivasyon toplamları işlem biçimine göre seçilmektedir.

- **Aktivasyon Fonksiyonu (f(x)):** Toplam fonksiyonundan aktarılan verileri girdiye karşılık üreteceği çıktı verilerinin belirlenmesine yardımcı olur. Bu fonksiyonda Doğrusal (Lineer) Aktivasyonu, adım (step) aktivasyonu, sigmoid aktivasyonu, tanjant hiperbolik aktivasyonu, eşik değer fonksiyon aktivasyonu ve sinüs aktivasyonu gibi fonksiyonlar ile işlem yapılır. Gelen girdiye uygun aktivasyon seçilirken doğrusal olmayan bir fonksiyonun türevinin kolay hesaplanıp hesaplanmadığına göre ayarlanır. Aktivasyonda seçilen türeveler bağı olarak geri beslemeli ve ileri beslemeli olarak iki şekilde belirlenir.
- **Çıktı:** Aktivasyondan aldığı verileri dış dünyaya ve almış olduğumuz veri modeline yakın sonuçlar vermeyi hedefleyen proses elemanıdır(Kurt, 2017).

2.1.2.1.1. Tek Katmanlı Yapay Sinir Ağları

Tek katmanlı algılayıcıların yapısında gizli katman bulunmamaktadır. Girdi ve çıktı olarak iki katmandan oluşur. Tek katmanlı detektör ile inşa edilen rasgele bir ağ, bir veya birden çok girdi ve çıktıdan oluşabilir. Girdi katmanları (X), ağırlıklar (W) aracılığıyla çıktı birimlerine (Ç) bağlanır. Bu tür yapılarda daima bir olan bir eşik değeri bulunmaktadır ve görevi süreçteki elemanlarının değeri sıfır olmasını engellemektir. Çıktı üniteleri bütün girdi ünitelerine (X) bağlanmaktadır ve her bağlantının bir ağırlığı (W) vardır. İki girdi ve bir çıktıdan oluşan tek katmanlı bir YSA Şekil 11’de verilmiştir(Şengöz, 2017).



Şekil 11. Tek Katmanlı YSA Modeli

Kaynak: (Şengöz, 2017)

2.1.2.1.2. Çok Katmanlı Yapay Sinir Ağları

YSA yapısının, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre ikiye ayrılmaktadır; ileri beslemeli (feed forward) ve geri beslemeli (feedback, recurrent) ağlardır(Ataseven, 2013).

2.1.2.1.2.1. İleri Beslemeli (Feed Forward) Yapay Sinir Ağı


İleri beslemeli YSA girdi, çıktı ve gizli katman olarak üç farklı aşamadan oluşmaktadır. Her katman birçok sinir ağından oluşmaktadır ve oluşan katmanlar kendi aralarında ağırlık matrisleri ile bağlanmaktadır. Katmanlar arasındaki YSA sayısı ve bağlantı şekli değiştirilebilmektedir. Oluşan katmanların aynı kısımdaki YSA arasında iletişim olmamasına izin verilmektedir. YSA girdiyi alırken ya başlangıç ya da ara girdilerden alırlar. İleriye doğru YSA iki bölümden oluşmaktadır:

- Çıktı katmanındaki hesaplanan ve incelenen veriler arasındaki değişikliklere bakılarak bağlantı kuvvetleri üzerinde farklılıkların yapıldığı bir geriye doğru ilerleme bölümüdür.

- Girdi katmanında verileri eğitmeye başlarken, bağlantı kuvvetleri arasında rastgele değerler atanmaktadır(Topal ve Topal, 2008).

Algoritma öğrenme sürecini tamamlayana kadar her iterasyonda eğitim başarısını tamamlayana kadar kuvveti değiştirmektedir. Eğitim başarı ile tamamlandıktan sonra iterasyon sürecinde elde edilen ve kullanılan örneklerdeki mevcut bilgi ve dokümanları saklar(Topaloğlu, 2007).

Yeni bir girdi kümesi yüklendiğinde, ileriye doğru besleme ile nöronların bağlantı ağırlıkları öğrenilmiş olur ve saklanan veriden dolayı bir çıktı kümesi elde edilir. Bir girdi, bir gizli katman ve bir çıktı bölümünden meydana gelen üç bölümlü bir öğrenme ağı Şekil 12’te de gösterildiği gibidir(Topaloğlu, 2007).




Şekil 12. İleri Beslemeli Yapay Sinir Ağlarının Modeli (İBYSA)

2.1.2.1.2.2. Geri Beslemeli (Feedback) Yapay Sinir Ağı

Geri Beslemeli yapay sinir ağları en az bir hücrenin çıktısı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme yöntemi, bir bölümdeki hücreler arasında olduğu gibi bölümler arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, doğrusal (lineer) olmayan dinamik bir davranış gösterir.

Geri Beslemeli YSA, geri beslemenin hazırlanış biçimine göre değişik yapıda ve harekette geri beslemeli YSA yapıları elde edilebilir. Bundan dolayı, bu bölümde bazı geri beslemeli YSA yapılarında örnekler verilecektir. Şekil 13’de görüldüğü üzere iki katmanlı ve çıkışlarından giriş katmanına geri beslemeli bir YSA yapısı görülmektedir(Öztemel, 2008).



Şekil 13. Geri Beslemeli Yapay Sinir Ağlarının Modeli (GBYSA)

2.1.2.1.2.3. Levenberg-Marquardt Algoritması

Yarı-Newton yöntemleri gibi, Levenberg-Marquardt algoritması da Hessian matrisini hesaplamak zorunda kalmadan ikinci dereceden eğitim hızına yaklaşmak için tasarlanmıştır. Performans fonksiyonu bir kareler toplamı biçimine sahipse (ileri beslemeli ağların eğitiminde tipik olduğu gibi), o zaman Hessian matrisi şu şekilde tahmin edilebilir:

$$H = J^T J \quad (2.1)$$

$$g = J^T e \quad (2.2)$$

Burada J. ağırlıklara ve önyargılara göre ağ hatalarının ilk türevlerini içeren Jacobian matrisidir ve e. ağ hatalarının bir vektörüdür. Jacobian matrisi, Hessian matrisini hesaplamaktan çok daha az karmaşık olan standart bir geri yayılım tekniği ile hesaplanabilir(Nawi, Khan, ve Rehman, 2013).

LM algoritması hızlı yakınsaması, kendi içerisinde az parametre bulundurması ve sadece birinci dereceden kısmi türevler ile işleme alınması bakımından faydalı olan bir algoritmadır. LM algoritmasında farkın karelerinin toplamının SSE amaç fonksiyonunu minimize edecek uygun değer ağ ağırlıkları W , k iterasyon basamağı aşağıda yer alan denklem yardımıyla bulunabilmektedir(Okkan et al., 2018).

$$\Delta W(k) = -[J_k^T J_k + \lambda_k]^{-1} J_k^T e_k \quad (2.3)$$

$\Delta W(k)$ k : İterasyonda ağ ağırlıklarındaki değişimi sembolize etmektedir.

J : Jakobien matrisinin sembolü olup ağ hataları olan e 'nin ağırlıklara göre birinci türevlerinden oluşmaktadır.

λ : Marquardt parametresini

I : Birim matrisi temsil etmektedir.

Marquardt parametresi de LM algoritmasında iterasyonlar boyunca güncellenebilen bir parametredir. Eğer herhangi bir iterasyon adımıda SSE azalıyorsa, λ bir sonraki iterasyon için belirli bir bozulma oranı (decay rate) ile çarpılarak sonuca ulaşmaktadır. Bu değer genelde 0.1 alınabilmektedir. Diğer durumlarda ise λ bir sonraki adım için belirlenen bozulma oranına bölünerek kullanılmaktadır ve bu işlemler yapılırken her bir iterasyonda ağın performansının iyileştirilmesi hedeflenmektedir(Okkan et al., 2018).

2.1.2.1.2.4. Bayesian Yöntemi

Bayes düzenlenmesi, Levenberg-Marquardt algoritması içinde gerçekleşir. Geri yayılım, X ağırlık ve sapma değişkenlerine göre performans performansının Jacobian jX 'ini hesaplamak için kullanılır. Her değişken, Levenberg-Marquardt'a göre ayarlanır(Mackay, 1992). Bayes düzenlenmesi, kare hataların ve ağırlıkların doğrusal bir kombinasyonunu en aza indirir. Ayrıca doğrusal kombinasyonu, eğitimin sonunda ortaya çıkan ağın iyi genelleme niteliklerine sahip olması için değiştirir(Mackay, 1992) .

Bu çalışmada yapay sinir ağları kullanılarak modelde hata oranları tespit edilmek istenmiştir. Modelde kullanılan hata oranları şu şekildedir;

1) Ortalama Mutlak Hata (Mean Absolute Error) [MAE]

Ortalama mutlak hata sürekli deęişken arasındaki farkın ölçülmesidir. MAE, bütün gerçek deęer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. MAE aynı zamanda her veri noktası ile en iyi uyan çizgi arasındaki ortalama yatay mesafedir. MAE'nin yönünü dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçen, tüm tekil hataların ortalamada eşit olarak ağırlıklandırıldığı doğrusal bir skordur. MAE deęeri 0'dan ∞ 'a kadar deęişebilir. Negatif yönelimli puanlar yani daha düşük deęerlere sahip tahminleyiciler daha iyi performans gösterir(URL5, 2021).

$$MAE = \frac{1}{n} \sum_{j=1}^n e_i \quad (2.4)$$

2) Ortalama Kare Hata (Mean Squared Error)

Basitçe, ortalama kare hata bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu söyler. MSE, bir makine öğrenmesi modelinin, tahminleyicinin performansını ölçer, her zaman pozitif deęerlidir ve MSE deęeri sıfıra yakın olan tahminleyicilerin daha iyi bir performans gösterdiği söylenebilir.

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (2.5)$$

3) Kök Ortalama Kare Hata (Root Mean Square Error)

Bir makine öğrenmesi modelinin, tahminleyicinin tahmin ettiği deęerler ile gerçek deęerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen kuadratik bir metriktir. RMSE tahmin hatalarının (kalıntıların) standart sapmasıdır. Yani kalıntılar, regresyon hattının veri noktalarından ne kadar uzakta olduğunu bir ölçüsüdür; RMSE ise bu kalıntıların ne kadar yayıldığıнын bir ölçüsüdür. Başka bir deyişle, verilere en iyi uyan çizgi etrafında o verilerin ne kadar yoğun olduğunu söyler. RMSE deęeri 0'dan ∞ 'a kadar deęişebilir. Negatif yönelimli puanlar yani daha düşük deęerlere sahip tahminleyiciler daha iyi performans gösterir. RMSE deęerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir. RMSE, büyük hataları daha fazla

cezalandırmanın avantajına sahiptir. Bu yüzden bazı durumlara daha uygun olabilir. RMSE, birçok matematiksel hesaplamada istenmeyen mutlak değerin kullanılmasını engeller(URL5, 2021).

$$RMSE = \sqrt{\sum_{j=1}^n e_j^2} \quad (2.6)$$

$$RMSE = \sqrt{MSE} \quad (2.7)$$

4) Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)

Regresyon ve zaman serileri modellerinde tahminlerin doğruluğunu ölçmek için ortalama mutlak yüzde hata sıkça kullanılmaktadır. Gerçek değerler arasında sıfır içerenler varsa sıfır ile bölünme olacağı için MAPE hesaplanamaz. Çok düşük tahmin değerleri için yüzde hatası %100'ü geçemez. Ancak çok yüksek tahmin değerleri olduğunda yüzde hatasının üst sınırı yoktur. MAPE, tahminleyicilerin doğruluğunu karşılaştırmak için kullanıldığında, tahminleri çok düşük olan bir yöntemi sistematik olarak seçmesi nedeniyle önyargılıdır. Bu ufak ama ciddi problemin, tahmin değerlerin gerçek değerlerine oranını bulan bir doğruluk ölçütü ile üstesinden gelinebilir. Bu yaklaşım geometrik ortalama açısından yorumlanabilen tahminlere yol açar(URL5, 2021).

$$MAPE = \frac{100}{n} \sum_j \frac{|e_i|}{|A_j|} \quad (2.8)$$

2.2. MAKİNE ÖĞRENMESİ

Makine öğrenmesi(MÖ), bilgisayarlara açık bir biçimde programlamadan öğrenme yeteneği kazandıran bir YZ türüdür(Alkan. 2017). MÖ, matematiksel ve istatistiksel yöntemleri kullanarak mevcut verilerden çıkarımlar yapan ve bu çıkarımlarla bilinmeyene ilişkin tahminlerde bulunan metot paradigmasıdır. MÖ, geniş bir uygulama yelpazesıyla bilgisayar biliminin en hızlı büyüyen alanlarından biridir. Geçmişte bazı akademik araştırmalar, belirli bir aşamadan sonra makinelerin verileri öğrenmesi

gerektiğini göstermiştir. Bunun sonucunda araştırmacılar çeşitli sembolik yöntemler kullanarak çeşitli problemlere yaklaşmak için bu çalışmaları yürüttüler(Sarle, 1994; Elen ve Avuçlu, 2020). Önemli sayıda bu yaklaşım, tahmin etme ve sınıflandırma becerisine sahiptir. MÖ algoritmaları, karar almak veya tahminler yapmak için açıkça programlanmadan, "eğitim verisi" olarak bilinen örnek verilere dayalı bir matematiksel model oluşturmaktadır(Bozyiğit ve Tarhan. 2020).

Makine öğreniminin amacı, bilgisayarları belirli bir sorunu çözmek için örnek verileri veya geçmiş deneyimleri kullanacak şekilde programlamaktır(Alpaydın, 2014).

Makine öğrenmesi mühendislik, bilgisayar bilimi, istatistik ve daha birçok disiplinin içinde kendine çalışma alanı bulmaktadır.

Politikadan yerbilimlerine kadar pek çok alanda başarıyla kullanılmakta ve birçok problemin çözümünde yararlanılmaktadır(Harrington, 2012). Öğrenme algoritmalarının kullanıldığı uygulamalara örnek verecek olursak(Mohri, Rostamizadeh, & Talwalkar, 2012);

Metin ve belge sınıflandırması, örnek olarak çok sayıda kişiye giden istenmeyen e- postaların tespit edilmesi,

- Doğal dil işleme, morfolojik analizler, istatistiksel ayrıştırma, metin parçası etiketleme, varlık ismi tanımlama,
- Konuşma tanıma, konuşma sentezleyici, konuşmacı doğrulama,
- Optik karakter tanıma,
- Sayısal biyoloji uygulamaları, örnek olarak protein yapı tahmini,
- Bilgisayarlı görme, örnek olarak görüntü ve yüz tanıma,
- Sahtekarlıkların saptanması (telefon ve kredi kartı), şebeke ihlali,
- Oyunlar, örnek olarak satranç ve tavlâ
- Yardımcısız araba kontrolü (navigasyon),
- Medikal tanı,
- Tavsiye sistemleri, arama motorları, bilgi çıkarım sistemleri

İstatistik, zeka modelleri uyumsal kontrol teorisi, psikolojik modeller, evrimsel modeller ve yapay zeka gibi disiplinler makine öğrenmesine katkıda bulunmaktadır(Nilsson, 1996).

2.2.1. Makine Öğrenmesi Yöntemleri

Makine öğrenme algoritmaları temel olarak beş farklı başlık altında değerlendirilmektedir. Bunlar;

2.2.1.1. Danışmanlı Öğrenme (Supervised Learning)

Danışmanlı öğrenme yönteminde, bir uzman tarafından oluşturulan örnek girdiler ve buna karşılık beklenen çıktılar modele sunulur. Modelin eğitim süreci, eğitim verilerinde istenen doğruluk seviyesine ulaşana kadar devam eder. Daha sonra modele yeni bir girdi sunularak tahmin edilmesi sağlanır. Bu öğrenme yöntemi, genel olarak regresyon ve sınıflandırma olarak iki alt grupta incelenir. Regresyon, sürekli bir miktarı tahmin etme problemidir. Sınıflandırma, gözlemlenen girdilerin kategorilere ayrılmasıdır(Avuçlu ve Elen, 2020). Kısacası verilerin birbirine etki ettiği sistemlerden alınarak belirli bir düzende organize edilmesidir(Alkan, 2017).

2.2.1.2. Danışmansız Öğrenme (Unsupervised Learning)

Danışmansız öğrenme yönteminde, modelin öğrenme sürecinde belirlenen örnek girdiler sunulur fakat herhangi bir beklenen çıktı(etiket) verilmez. Bu sebeple, girdi verisinin hangi sınıfa ait belirsizdir ve girdi parametreleri arasındaki ilişkileri bizatihi öğrenmesi beklenir. Bu öğrenme yönteminde, ele alınan problemlerin büyük bir çoğunluğu kümeleme üzerinedir. Kümeleme, ortak bir grubun üyelerinin birbirlerine benzer ve diğer grupların üyelerinden farklı olacak şekilde gözlemlerin birlikte gruplanması anlamına gelir(Avuçlu ve Elen, 2020).

2.2.1.3. Yarı Danışmanlı Öğrenme(Semi-Supervised Learning)

Yarı danışmanlı öğrenme yöntemi ise danışmanlı ve danışmansız öğrenme yöntemlerinin arasındadır. Çünkü yöntem eğitim için hem etiketli hem de etiketlenmemiş verileri kullanır. Bu yöntemi kullanan sistemler öğrenme doğruluğunu büyük bir oranla iyileştirebilir. Genellikle, bu yöntemde elde edilen etiketli veriyi eğitmek /ondan öğrenmek için yetenekli ve ilgili kaynaklar gerektirdiğinde seçilir. Aksitakdirde, etiketlenmemiş verilerin toplanması genellikle ek kaynaklar gerektirmez.(Avuçlu ve Elen, 2020). Sonuç olarak, yarı danışmalı öğrenme yöntemi tam olarak danışmanlı ve danışmansız kavramların yer aldığı ve etiketlenmemiş büyük miktarda bir veri ile etiketlenmiş küçük miktarda bir verinin beraber kullanılmasıdır(Alkan, 2017).

2.2.1.4. Takviyeli Öğrenme (Reinforcement Learning)

Takviyeli öğrenme yönteminde, eylemler üreterek çevresiyle etkileşime geçen olumlu veya olumsuz durumları keşfeden bir yöntemdir. Bu yöntemde bir danışman/eğitici bulunur fakat danışmanlı öğrenme modellerindeki gibi sisteme çok detay vermez veya müdahale etmez. Bunun yerine, öğrenen model bir karar verdiğinde, kararın doğru olduğu durumlar için sistemi ödüllendirir ve yanlış olduğunda ise cezalandırır(Avuçlu ve Elen, 2020)Öğreticinin, sistemin ürettiği modelin sonucunu doğru ve yanlış olmasını yorumlaması ve denetlemesidir.

2.2.1.5. Yoğun Öğrenme (Intensive Learning)

Hiyerarşik öğrenme olarak da bilinmektedir. Bu öğrenme yöntemi derin grafiklerde birçok doğrusal ve doğrusal olmayan dönüşümlerden ve çoklu işlem katmanlarından oluşturulmuş verilerde, üst düzey soyutlamalar kullanılarak elde edilen model girişimlerine dayalı bir dizi algoritmalarla geliştirilmiş makine öğrenmesidir(Alkan, 2017).

Makine öğrenimi değişen şartlarda bile verilerin anlam kazanması hedefiyle bilgisayar programlarının geliştirilmesi amaçlanmıştır. Son yıllarda büyük bir ivme kazanmış olsa da makine öğrenmesi aslında bilgisayar tarihi kadar eskidir. İlk bilgisayarların kullanılmaya başlanmasından bu yana veriler birçok farklı yollarla işlenerek anlam kazandırılmak istenmiştir(Büber, 2018).

2.2.2. Makine Öğrenmesi Terminolojisi

Algoritmaların öğrenme sürecinde öncelikle ham veriler bulunur ve algoritmaya iletilir. Bu veriler genel olarak sayısal ölçümler. Puanlamalar, metin gibi bilgilerdir. Bir kaç adımda verilerin öğrenilmesi ve eğitilmesi sağlanır.

2.2.2.1. Model Oluşturma

Bir problemin çözümüne yönelik, belirli verilerin öğrenilmesi amacıyla bir ya da daha fazla makine öğrenme algoritması kullanılarak oluşturulan bir sistemdir. Diğer bir adı ise hipotez olarak bilinmektedir(Avuçlu ve Elen, 2020).

2.2.2.2. Özellik (Feature) Çıkarımı

Verilerin kişisel olarak ölçülebilir özelliği vardır. Nicel özellikler kümesi, bir özellik vektörü tarafından kolayca tanımlanabilir. Özellik vektörü oluşturulan modelin

girdilerini temsil eder. Problemin çözümü açısından ayırt edici, bilgilendirici ve bağımsız özellikleri seçmek algoritmalar için çok önemli bir adımdır. Ham verilerden ilgili özellikleri çıkarmak için genellikle bir özellik çıkarıcı yöntemi kullanılır(Avuçlu ve Elen, 2020)

2.2.2.3. Hedef (Target)

Konu ile ilgili oluşturulan model tarafından tahmin edilecek değeri temsil etmektedir ve etiket(label) olarak ta adlandırılabilir(Avuçlu ve Elen, 2020).

2.2.2.4. Eğitim (Training)

Ele aldığımız girdi(özellik) verileri ve beklenen çıktı(etiket) verilerinin sonucunu vermektedir ve böylelikle yeni verilerden eğitilenler yeni kategorilerden birine atayacak veya eşleştirecek modelimiz oluşacaktır(Avuçlu ve Elen, 2020)

2.2.2.5. Tahmin (Prediction)

Eğitilen girdi verilerin sonuca ulaştığında öngörülen çıktı(etiket) sağlayacağı bir dizi veri ile beslenir(Elen ve Avuçlu, 2020). Bu süreçler verilerimizin başarı oranını yüzdesel olarak artırması için oldukça önemlidir. Şayet değerlendirme sonucunda istenilen sonuçlara ulaşılamaz ve modelin başarılı olmadığı düşünülürse iyileştirme yapılır. Bazı eklemeler yapılarak yeniden model oluşturulur ve oluşturulan model tekrar testlerden geçirilir. Bu süreç istenilen sonuç elde edilene kadar devam edebilir.

2.2.3. Makine Öğrenmesinin Ölçekleri


Makine öğrenme algoritmaları temel olarak beş farklı ölçek vardır. Bunlar;

2.2.3.1. Accuracy (Doğruluk)

Doğruluk, yapılan araştırmada kullanılan verilerin doğru veri değerlerine ne kadar yakınlığı anlamına gelmektedir. Bir ölçüm sisteminin hassasiyeti, tekrarlanan ölçümler arasında ölçümlerin birbirine ne kadar yakın olduğunu ifade eder (aynı koşullar altında tekrarlanma). Doğruluk dört koşulda değerlendirilir.

- Ölçümler hem doğru hem kesin
- Doğru ama kesin değil
- Kesin ama doğru değil
- Ne kesin nede doğru olmayabilir(URL2, 2021).

Model başarımının ölçülmesinde kullanılan en popüler ve basit yöntem, modele ait doğruluk oranıdır.



Şekil 14. Doğruluk Ölçütü

TP: Değer Pozitif Doğru

FN: Değer Negatif Yanlış

FP: Değer Pozitif Yanlış

TN: Değer Negatif Doğru

Matematiksel gösterimi;

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.9)$$

2.2.3.2. Sensitivity (Duyarlılık)

Bir testin duyarlılığı gerçek pozitif oran olarak adlandırılır. Örneğin, bir paneldeki tüm pozitif örnekleri doğru şekilde tanımlayan bir test çok hassastır. Paneldeki pozitif örneklerin yalnızca %60'ını saptayan başka bir test, eksik pozitifler olduğundan ve yanlış negatif oran verdiğinden çok daha düşük duyarlılığa sahip olduğu kabul edilmektedir. Tip II hatalar olarak da bilinmektedir (Steward, 2019)

$$Sensitivity = \frac{TP}{TP + FN} \quad (2.10)$$

2.2.3.3. Specificity (Belirginlik)

Belirginlik ifadesi testin, gerçek negatif oranı (TNR), test negatif gerçekten negatif söz konusu test kullanılarak bu örneklerin oranıdır. Örneğin, tüm sağlıklı insanları belirli bir hastalık için negatif olarak tanımlayan bir test çok spesifiktir. Sağlıklı kişilerin %30'unu hatalı olarak bu duruma sahip olarak tanımlayan başka bir test, daha yüksek yanlış pozitif oranına (FPR) sahip olarak daha az spesifik olarak kabul edilecektir. Tip I hatalar olarak da adlandırılan yanlış pozitifler, gerçek bir boş hipotezin reddedilmesidir (boş hipotez, örneğin negatif olduğudur).

$$Specificity = \frac{TN}{TN + FP} \quad (2.11)$$

2.2.3.4. Precision (Hassaslık)

Hassaslık (Precision) değeri pozitif olarak tahminlenmesi gereken değerlendirmelerin ne kadarının pozitif olarak tahmin ettiğimizi gösteren bir metriktir (Göçgün ve Onan, 2021)

$$Precision = \frac{TP}{TP + FP} \quad (2.12)$$

2.2.3.5. F-Skor(Score)

Basit bir ortalama yerine harmonik ortalama olmasının nedeni ise uç değerleri de göz ardı etmememiz gerektiğidir. Basit bir ortalama hesaplaması olsaydı değeri 1 ve duyarlılık değeri 0 olan bir modelin F1 Skor'u 0.5 olarak gelecektir ve bu analizin sonucu bizi yanıltacaktır.

Doğruluk yerine F1 Skor değerinin kullanılmasının birinci sebebi eşit dağılmayan veri kümelerinde seçilen bir modelin hatalı bir model olmamasıdır. Ayrıca yalnızca False Negative veya False Positive değil tüm hata maliyetlerini de içerecek bir ölçme metriğine ihtiyaç olduğu için F1 Skor analizimiz için çok önemlidir (Öğündür, 2019)

$$Fscore = \frac{2}{\frac{1}{TPR} + \frac{1}{PPV}} \quad (2.13)$$

Değerlendirme sonucunda istenilen sonuçlara ulaşılamaz ve modelin başarılı olmadığı düşünülürse iyileştirme yapılır. Bazı eklemeler yapılarak yeniden model oluşturulur ve oluşturulan model tekrar testlerden geçirilir. Bu süreç istenilen sonuç elde edilene kadar devam edebilir.

2.2.4. Makine Öğrenmesinde Sınıflandırma

Makine Öğrenimindeki sınıflandırma, kesikli veya sürekli özellik değerlerinin bir vektörünü girdi (özellik) ve tek bir ayrık değer olan sınıfı çıktı(etiket) bir sistemdir. Bir dizi öğrenim kategorisini veya sınıfını tahmin etmek için sınıflandırma algoritmaları kullanılır. Sınıflandırma algoritmaları:

- K-Nearest Neighbors (K-En Yakın Komşular)
- Naive Bayes
- Decision Trees (Karar Ağaçları)
- Standardized Variable Distances (SVD)(Standartlaştırılmış Değişken Mesafeler)
- Support Vector Machine (Destek Vektör Makinesi)
- Random Forest(Rastgele Orman) gibi algoritmalarıdır.

Bu çalışmada beş katlımanlı çapraz doğrulama tekniği kullanılmıştır. Bu teknik, literatürde **k-fold cross validation** olarak bilinmektedir. Makine öğrenme modellerinin sınıflandırma başarılarının değerlendirilmesi amacıyla kullanılır.

2.2.4.1. En Yakın K Komşu Algoritması (K- Nearest Neighbor)

K-NN algoritması, 1967 yılında Cover ve Hart tarafından önerilmiştir(Cover, TM ve Hart, 1967). K-NN, öznitelik uzayındaki en yakın eğitim örneklerine bağlı olarak nesneleri sınıflandıran, en temel örüntü tanıma ve sınıflandırma yöntemlerinden birisidir. Buradaki amaç, “**k**” değeri kadar en yakın komşunun ait olduğu sınıfa göre yeni örneğin hangi sınıfa ait olacağına karar vermektir. Yeni bir vektörün sınıfını belirlemek için eğitim verisinden daha önce sınıflandırılmış olan en yakın k adet örnek seçilir. Buna göre yeni vektör, seçilen örneklerin ait olduğu sınıflara bakılarak çoğunlukta olan sınıf hangisi

ise ona atanır. Yeni bir örneğin, sınıflandırılmış olan örneklerle göre mesafelerinin hesaplanması için farklı yöntemler (Öklid, Manhattan, Minkowski vb.) vardır. Bunlardan en yaygın olanı ise Öklid uzaklık hesaplama yöntemidir (Eşitlik 1).

$$d(i, j) = \sqrt{\sum_{p=1}^n (X_{ip} - X_{jp})^2} \quad (2.14)$$

Burada n , boyutu temsil etmektedir. i ise sınıflandırılacak olan yeni bir örneğin (X_{jp}), en yakınındaki k komşularını $X_{ip}(i = 1, 2, \dots, k)$ ifade etmektedir.

2.2.4.2. Naive Bayes (NB) Sınıflandırıcısı

Bayes teoremine (Thomas Bayes, 1702-1761) dayanan basit bir olasılıksal sınıflandırma yöntemidir. Bayes teoreminde (BT), birbirinden bağımsız olan ve rastgele iki olayın (X ve Y) arka arkaya gerçekleştiği durumlarda, bu iki olaydan birinin gerçekleşmesi durumunda ikinci olayın gerçekleşme olasılığı $P(X \cap Y)$ ifadesi ile gösterilebilir. Değişme özelliği sayesinde (Eşitlik 2) gibi çarpım kuralı iki farklı ifade ile yazılabilir;

$$P(X \cap Y) = P(X|Y)P(Y) = P(Y|X)P(X) \quad (2.15)$$

Bayes teoremi, rassal bir süreçle ilgili olarak ortaya çıkan rasgele bir X olayı ile diğer bir rasgele Y olayı için koşullu olasılıklar ve marjinal olasılıklar arasındaki ilişkiyi tanımlar (Eşitlik 3).

$$P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)} \quad (2.16)$$

Herhangi bir problemde gerçekleşmesi muhtemel bağımlı durumların olasılıkları yukarıda verilen Bayes eşitliği ile hesaplanır. Bu eşitlikte $P(X)$ ifadesi problemin girdi olasılığını, $P(Y)$ ifadesi olası çıkış durumunun olasılığını ve $P(Y|X)$ ifadesi ise daha önce gerçekleşen X girişine karşın Y çıkışı durumlarının olasılığını temsil

etmektedir(Orhan ve Adem. 2012). NB sınıflandırma tekniğinde, her bir ilişkiden koşullu bir olasılık oluşturmak için bağımlı ve bağımsız özellikler arasındaki ilişkiyi analiz eder. Yeni bir örneği sınıflandırmak için bağımlı değişken üzerinde bağımsız değişkenlerin etkilerini birleştirerek bir tahmin yapılır(Krishna ve De, 2005)

2.2.4.3. Decision Tree (Karar Ağacı)

Belirli bir kritere göre veri setinin sürekli olarak bölünmesiyle verileri sınıflandırabilen danışmalı bir makine öğrenme algoritmasıdır. Bir karar ağacı yapısı kök, düğüm, dal ve yaprakтан oluşur. Ağaç yapısında en altta kalan kısım yaprak en üstte olan kısma ise kök adı verilir. Veri setinde bulunan her bir nitelik ise düğüm noktalarını temsil etmektedir. Düğümler arası bağlantıyı sağlayan kısım ise dal olarak adlandırılır. Karar ağaçlarında bölümlmeye hangi düğümden başlanacağı çok önemlidir. Uygun düğümden başlanmazsa ağacın içerisindeki düğümlerin ve yaprakların sayısı çok fazla olacaktır. Literatürde birçok karar ağacı öğrenme algoritması mevcuttur(Elen ve Turan, 2019) Bu çalışmada ise C4.5 algoritması tercih edilmiştir. Bu işlem için ilk olarak Eşitlik 4'te gösterildiği şekilde sınıf niteliğinin entropisi hesaplanır.

$$H(S) = -\sum_{i=1}^n p_i \log_2(p_i) \quad (2.16)$$

Bir sonraki aşamada, Eşitlik 5 ve Eşitlik 6'da gösterildiği gibi özellik vektörlerinin sınıfa bağımlı entropileri hesaplanır.

$$H(X_k) = -\sum_{i=1}^n \frac{|S_i|}{|X_k|} \log_2 \frac{|S_i|}{|X_k|} \quad (2.17)$$

$$H(X, S) = -\sum_{k=1}^n \frac{|X_k|}{|X|} H(X_k) \quad (2.18)$$

Son olarak, sınıf niteliğinin entropisinden tüm özellik vektörlerinin entropisi çıkartılarak her bir özellik için kazanç ölçütü hesaplanır. Bunun için Bilgi Kazancı, Gini

indeksi ve Towing kuralı yaygın olarak kullanılan yöntemlerdir. Bu çalışmada karar verme kıstası olarak “Bilgi Kazancı” yöntemi kullanılmıştır (Eşitlik 7).

$$IG(X, S) = H(S) - H(X, S) \quad (2.19)$$

2.2.4.4. Standardized Variable Distances (SVD)

Literatürde “minimum (or mean) distance classifier” MDC olarak bilinen sınıflandırıcının, verilerdeki varyans duyarsızlığını ortadan kaldıran bir algoritmadır. Bu yöntemde, özellikle gürültülü verilerde yanlış sınıflandırma riskini minimum seviyeye getirmesi amaçlanmıştır (Elen ve Avuçlu, 2021). SVD’de her bir sınıf etiketi için giriş vektörlerinin ortalama değerleri hesaplanarak. Eşitlik 8’te gösterildiği centroid sınıf vektörleri ya da diğer bir ifadeyle centroid sınıf matrisi ($\mu V \in \mathbb{R}^{k \times n}$) elde edilir.

$$\mu V = \sum_{a=0}^k \sum_{j=0}^n \mu V[a, j] = \left\{ \sum_{i=0}^m \{x_{i,j}, \quad c_a = y_i / \sum_{i=0}^m \{1, \quad c_a = y_i \right. \quad (2.20)$$

Burada $x_{i,j}$ giriş vektöründeki i -inci örneğin j -inci özniteliğini, y_i i -inci örneğe ait çıkış değerini, c_a sınıf etiketini ve $\mu V[a, j]$ ise sentroid sınıf matrisinin a -inci vektörünün j -inci özniteliğini temsil etmektedir. Daha sonra her bir giriş vektörünün centroid sınıf vektörlerine olan uzaklıkları ($dX \in \mathbb{R}^k$), Eşitlik 9’te gösterildiği gibi hesaplanır.

$$dX = \sum_{i=0}^k \{dX[i] = \text{distance}(X, \mu V[i, *]), X | X \in v_X \quad (2.21)$$

Burada k sınıf etiketini ve X veri setindeki bir giriş vektörünü temsil etmektedir. Mesafe ölçümünü temsil eden **distance**($X, \mu V$) fonksiyonu için Euclidean, Manhattan, Minkowski, Chebyshev, Hellinger, Angular vb. metotlardan biri kullanılmaktadır. Bir sonraki aşamada, her bir sınıf için giriş vektörlerinin standart sapma matrisi ($\sigma V \in \mathbb{R}^{k \times n}$) Eşitlik 10’da gösterildiği gibi elde edilir. Standart sapma, bilindiği üzere veri analizi açısından önemli bir parametredir. Özellikle gürültülü verilerin sınıflandırılmasında algoritmanın performansı açısından etkili bir rol oynamaktadır.

$$\sigma V = \sum_{a=0}^k \sum_{j=0}^n \sigma V[a, j] = \left\{ \sqrt{\sum_{i=0}^m \left\{ (x_{i,j} - \mu V[a, j])^2 \right\}}, \quad c_a = y_i \right\} / \sum_{i=0}^m \{1, \quad c_a = y_i \quad (2.22)$$

Bir sonraki aşamada, veri setindeki bir giriş vektörü için standart normal dağılımın ya da daha yaygın bilinen adıyla z-skorun mutlak değerleri ($\mathbf{Z} \in \mathbb{R}^k$) Eşitlik 11'deki gibi hesaplanır.

$$Z = \sum_{i=0}^k Z[i] = \left\{ \sum_{j=0}^n \frac{|X_j - \mu V[i, j]|}{\sigma V[i, j]}, \quad X | X \in v_X \quad (2.23)$$

Burada X_j veri setindeki bir giriş vektörünün j -inci öz niteliğini, n giriş vektöründeki öz nitelik sayısını ve k ise sınıf sayısını temsil etmektedir. En son aşamada, her bir giriş vektörünün Eşitlik 3'te tanımlanan sınıflar için benzerlik skorları Eşitlik 8'deki gibi hesaplanır.

$$Decision = \arg \min_i (i | i \in c, dX[i] Z[i]) \quad (2.24)$$

Burada $i \in c$ sınıf etiketini temsil etmektedir. Z-skorunun mutlak değeri, ortalama değerden kaç standart sapma uzakta olduğunu gösterir. Eğer bir Z-skoru sıfıra eşitse, sunulan örnek ile centroid sınıf vektörü aynı değerdedir.

2.2.5. Makine Öğrenmesi Doğrulama Yöntemleri

2.2.5.1. Çapraz Doğrulama Yöntemi

Çapraz Doğrulama, bir makine öğrenmesi modelinde yapılan testin hatasını daha iyi tahmin edebilmek için model yapısı seçiminde kullanılan bir tekniktir. Çapraz doğrulamanın ana yapısı, eğitim verileri setinden doğrulama yani test kümeleri olarak bilinen örnek gözlem kümelerini oluşturmaktır. Modelde eğitim verilerini yerleştirdikten

sonra performans her yeni test kümesinin nasıl performans göstereceğine ilişkin daha iyi bir sonuç elde etmektir.

Çapraz doğrulamada her iterasyonda farklı test verisi ile eğitim verisi arasında kümeleme yapıp eğitmektir. Oluşturulacak bölüm sayısı, örnek veri kümesindeki gözlem sayısına ve önyargı varyansı dengelemesine ilişkin kararın daha fazla bölünmenin daha küçük bir yanlılığa yol açmasına ve daha fazla varyansa bağlı olarak değişmesine bağlıdır(Url10, 2021)

Çapraz doğrulama adını aynı veri üzerinde örneklerin farklı şekillerde gruplanmasından yani çapraz bir şekilde alınarak grupların oluşmasından alır. Çaprazlanan gruplar üzerinde yapılan sına sonuçları birleştirilerek modelin genel tahmin başarısı ölçülür. Çapraz doğrulama yöntem olarak ikiye ayrılmaktadır.

2.2.5.1.1. K-Parçalı Çapraz Doğrulama

K-parçalı doğrulama yöntemi, toplam n örneğin bulunduğu bir veri setinde her birinde $\frac{n}{k}$ örneğin bulunduğu k adet farklı kümeye parçaya ayrılır. Her defasında farklı bir veri seti kümesi test için ayrılarak geriye kalan diğer $k-1$ veri seti eğitim için kullanılır. Her defasında test kümesi değiştirilerek sınıflandırıcı k adet eğitilir. Böylelikle elde edilen k adet hatanın ortalaması ile sınıflandırıcı performansı tahmin edilmiş olur(Narin, İşler, ve Özer, 2014).

2.2.5.1.2. Birisi Dışarıda Çapraz Doğrulama Yöntemi

Bu yöntemde, n adet örneğin bulunduğu veriler n parçaya kadar bölünür, n parçaya bölünmüş veri setinde her seferinde bir örnek dışarıda kalacak biçimde geriye kalan tüm veriler $(n-1)$ ile sınıflandırıcı eğitilir ve bu eğitme tüm örnekler için tekrarlanır. Gerçekte örnek sayısı kadar k parçaya ayrılan k-Parçalı Çapraz Doğrulama Yöntemi gibi düşünülmektedir(Narin et al., 2014).


ÜÇÜNCÜ BÖLÜM

3.1. GÜNEŞ IŞINIMININ YAPAY SİNİR AĞLARI VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ANALİZİ

Bu bölümde, MATLAB paket programının arayüzü tanıtılmıştır. YSA ve MÖ yöntemleri ile güneş ışıınım verilerinin analizi yapılmıştır.

3.1.1. MATLAB Yapay Sinir Ağları Tasarımcısı


MATLAB Ana Ekran



Şekil 15. MATLAB Ana Ekran


-  **Menu Çubuğu:** MATLAB editöründe temel menülerin bulunduğu kısım olarak nitelendirilir.
-  **Dosya Gezini:** MATLAB ile açılan projenin dosyalarına ulaşılacak alan olarak tanımlanır.
-  **Komut Penceresi:** MATLAB komutlarının çalıştırılacağı alan olarak tanımlanır.

Yapay Sinir Ağları Tasarımcısının Açılması




Şekil 16. Yapay Sinir Ağları Tasarımcısının Açılması

Burada sistemin çalıştırılabilmesi için verinin tanımlanması aşaması öncelikli işlemdir. Gerekli analizlerin yapılabilmesi için verinin bir kısmı eğitim seti olarak bir kısmı da test olarak ayrılmıştır. Toplam 1818 verinin %15'i test seti olarak belirlenmiştir. Eğitim seti MATLAB bünyesinde input(giriş); test seti output(çıkış) olarak belirlenmiştir.




Şekil 17. Analiz Komutu

Burada tanımlanan giriş ve çıkış veri setlerinin yapay sinir ağları tekniği analizi sağlamak için komut yardımıyla çağırılması sağlanmıştır. “nnstart” komutu ile yapay sinir ağları tekniğinin başlatılması sağlanmıştır.




Şekil 18. Neural Network Start(nnstart) – Yapay Sinir Ağlarının Başlatılması

Burada başlatılan yapay sinir ağlarından Time Series App yani zaman serisi uygulamasını seçerek zaman serisi modelinin tanımlanması sağlanmaktadır. Bir zaman serisi bir veya daha fazla ölçülen çıkış kanalı içeren ancak ölçülen giriş içermeyen verilerdir. Sinyal modeli olarak da adlandırılan bir zaman serisi modeli, belirli bir sinyal veya zaman serisi verilerine uyacak şekilde tanımlanan dinamik bir sistemdir. Zaman serileri çok değişkenli olabilir. bu da çok değişkenli modellere yol açmaktadır.




Şekil 19. Neural Time Series(ntstool)- Sinirsel Zaman Serileri (ntstool)

Burada Nonlinear Autoregressive (NAR) seçeneği ile devam edilmektedir. Çünkü NAR sinir ağları, bu serinin geçmiş değerlerinden bir zaman serisini tahmin etmek için eğitilebilirler. NAR bir sinir ağını eğitir ve yeni zaman serisi verilerini tahmin eder. Bir zaman serisindeki bir dizi değeri tahmin etmek çok adımlı tahmin olarak da adlandırılabilir. Kapalı döngü ağlar, çok adımlı tahminler gerçekleştirebilmektedirler. Harici geribildirim eksik olduğunda kapalı döngü ağlar dahili geri bildirimi kullanarak tahmin etmeye devam etmektedir. NAR tahmininde, bir zaman serisinin gelecekteki değerleri yalnızca o serinin geçmiş değerlerinden tahmin edilebilirler. Daha sonra next butonuna basılarak işleme devam edilir.




Şekil 20. Hedef Veri ve Zaman Serisi Formatının Belirlenmesi

Burada hedefimizi çıktı olarak belirleyerek sütunlar formatında olan veri setimizi satır matrisleri olarak çeviriyoruz. Satır matrisleri olarak çevirmemizin nedeni hücre dizisindeki değerlerin yeri değiştirilebilir. Sütun örnekleri yalnızca x matrisinin veya hücre dizisi x' teki matrislerin yeri değiştirilecektir. Bununla birlikte satır örnekleri artık sütun vektörleri olarak depolanacaktır. Eğer zaman hücresi yalnızca matris örnekleri bir hücre dizisinin sütunlarına ayrılacaktır. Böylece başlangıçta bir matristeki vektörler olarak temsil edilen zaman artık bir hücre dizisinin sütunları olarak temsil edilecektir. Yanlış anlaşılmalara engel olmak için satır matrisine (matrix row) yani burada matris olduğu için çarpma yapmasından dolayı transpozisini alıyoruz.



Şekil 21. Eğitim, Doğrulama ve Test Yüzdeliklerinin Belirlenmesi


Bu aşamada veri setimizin eğitim(target), doğrulama(validation) ve testing(test) yüzdelikleri belirlenmektedir. Validation ve testing yüzdeliklerini %15 olarak tanımlanarak daha iyi sonuç verdiği tespit edilmiştir. Next butonu ile bir sonraki aşamaya geçilir.



Şekil 22. Network Architecture- Ağ Mimarisi


Burada nöron sayısı ve gecikmeleri belirlenmektedir. Ağ şekilde gösterildiği gibi açık döngüde oluşturulacak ve eğitilecektir. Açık döngü (tek adımlı) tahmini ile eğitim, kapalı döngü (çok adımlı) tahmininden daha etkilidir çünkü ağa doğru geri bildirim çıktıları sağlamamıza olanak tanımaktadır.

Eğitimden sonra ağ uygulamanın gerektirdiği herhangi bir yerden veya başka bir yerden kapalı döngüye dönüştürülebilir.




Şekil 23. Train Network – Eğitim Ağı

Bu aşamada bu algoritma tipik olarak daha fazla bellek ancak daha az zaman gerektirir. Doğrulama örneklerinin ortalama kare hatasındaki artışla gösterildiği gibi genelleme gelişmeyi bıraktığında eğitim otomatik olarak duracaktır. En yüksek başarımların elde edilebilmesi istenildiği kadar eğitim tekrarlanabilir.




Şekil 24. Evaluate Network- Ağın Değerlendirilmesi

Burada ağın daha fazla veri üzerinden isteğe bağlı olarak test edilebilir ardından ağ performansının yeterince iyi olup olmadığına karar verilebilir. Next(devam) butonuna tıklayarak işleme devam edilebilir.




Şekil 25. Deploy Solution – Çözüm Dağıtımı

Bu aşamada eğitilmiş sinir ağının konuşlandırılan sürümleri oluşturulabilir. Next(Devam) butonu ile işleme devam edilebilir.



Şekil 26. Save Results- Sonuçların Kaydedilmesi

Burada MATLAB komut dosyaları oluşturulabilir, sonuçlar kaydedilebilir ve diyagramları oluşturulabilir. Simple Script(Basit Komut Dosyası) veya Advance Script(Gelişmiş Komut Dosyası) ile açılan komut dosyasında elde etmek istediğimiz sonuçların kodları ekleyerek sonuçlara ulaşabiliriz.



Şekil 27. Komut Dosyası

Komut dosyasına herhangi bir müdahale yapılmadan önce yapay sinir ağıları analizi sonucunda bizlere MSE ve R değerini vermektedir. Çıktılar ve hedefler arasındaki ortalama kare farkıdır. Daha düşük değerler daha iyi sonuç anlamına gelir.

R değerleri ise çıktılar ve hedefler arasındaki korelasyonu ölçer. R değerinin 1 yakın olması yakın ilişki R değerinin 0 olması rastgele bir ilişki anlamına gelmektedir.

Burada performance (performans) değeri MSE değerini temsil ederken Performance2 (performans2) değeri RMSE4 değerini ifade etmektedir.

RMSE, karesel hataların ortalamasının kareköküdür. Her hatanın RMSE üzerindeki etkisi hatanın karesinin boyutuyla orantılıdır; bu nedenle daha büyük hataların RMSE üzerinde orantısız olarak büyük bir etkisi vardır.

Performance3(Performans3) ile MAE4 Ortalama Mutlak Hata değeri elde edilmektedir. Ortalama mutlak hata iki sürekli değişken arasındaki farkın ölçüsü olarak tanımlanır. MAE, her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. Ortalama mutlak hata aynı zamanda her veri noktası ile en iyi uyan çizgi arasındaki ortalama yatay mesafedir. Daha sonra MAPE değerini elde edebilmek için tahmini değerlerin gerçek değere oranı ile hesaplanarak bulunmaktadır. MAPE tahminlerin doğruluğunu ölçmek için kullanılmaktadır.

⁴ Mean Absolute Error

3.2. BULGULAR

3.2.1. Verinin Elde Edilmesi

Bu çalışmada kullanılan veriler Ankara Meteoroloji Genel Müdürlüğü'nden Bandırma Onyedi Eylül Üniversitesi Sosyal Bilimler Enstitüsü'nün onayı ve izini ile alınmıştır. Veri seti Türkiye'nin Marmara Bölgesi'nde bulunan güneş ışıınımı ölçümü yapan istasyonların verisinden oluşmaktadır. Bu istasyonların için yapılan ön analiz sonucunda Bursa ve Çanakkale illerine ait olan veriler üzerinde analiz yapmanın uygun olduğu tespit edilmiştir. Bu nedenle çalışmada, 2015-2019 yıllarına ait günlük/saatlik güneş ışıınım, toplam yağış, nispi nem, buharlaşma, saatlik güneşlenme süresi ve aktüel basınç değişkenleri üzerinde analiz yapılmıştır. Çalışmada oluşturulan modelde bağımlı değişken(Y) olarak günlük/saatlik güneş ışıınımı, bağımsız değişken olarak da toplam yağış (X_1), nispi nem (X_2), buharlaşma (X_3), saatlik güneşlenme süresi (X_4) ve aktüel basınç(X_5) verileri setleri kullanılmıştır.

3.2.2. Verilerin Düzenlenmesi

Meteoroloji Genel Müdürlüğü'nden alınan veriler analize uygun duruma getirilip düzenlenmiştir. Sonra verilerin normal dağılıma uygunluğu araştırılmıştır. Sonuç olarak verilerin normal dağılmadığı belirlenmiş ve verilere normalizasyon işlemi Eşit 13'te görülen formül ile yapılmıştır.

$$Z = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

3.2.3. Yapay Sinir Ağların Analiz Sonuçları

Analizin çözümü için MATLAB paket programı kullanılmıştır. Veriler MATLAB programına sunulurken normalizasyon yapılmıştır. Zaman serileri kullanılmış olup YSA'daki bütün modeller denenmiştir. Denenen modellerin sonuçları birbirine yakın çıkmış fakat en iyi sonucu veren NAR Eşit 1 'de modeli analiz sonucu bu tez çalışmasında kullanılmıştır. Bursa ve Çanakkale illerine ayrı ayrı aynı işlemler uygulanmıştır.

$$y(t) = f(y(t-1), \dots, y(t-d)) \quad (3.2)$$

Denenen modeller;

- Harici Girişli Doğrusal Olmayan Otoregresif (Nonlinear Autoregressive with (Exogenous) Input(NARX))


$$y(t) = f(x(t-1) \dots x(t-d).y(t-1) \dots y(t-d)) \quad (3.3)$$

- Doğrusal Olmayan Giriş-Çıkış (Nonlinear Input-Ourput)

$$y(t) = f(x(t-1) \dots x(t-d)) \quad (3.3)$$


Oluşturulan modeldeki verilerin %70 i yani 1272 veri eğitim. %15 yani 273 veri hem doğrulama hem de test için kullanılmıştır. Toplam 1818 veri seti çalışmaya dâhil edilmiştir. Gizli nöron sayısı olarak 10 katman seçilmiş olup gecikme sayısı yani $t=2$ seçilmiştir.

Oluşturulan YSA modelinin eğitimi sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ilişkin hata değerlerinin değişimini gösteren grafik Bursa için Grafik 1’de ve Çanakkale için Grafik 2’de verilmiştir. Verilerin grafikte görüldüğü gibi ağın eğitimi için iterasyon sayısı 1000 olarak ele alınmıştır fakat verilerin büyüklüğünden dolayı MATLAB programı Bursa modeli için 12 epoch yani iterasyona kadar eğitimini yapmış olup en iyi sonucu 6’ncı iterasyon sonucunda hesaplamıştır. En iyi eğitim olarak 0.028451 değerine varılmıştır.



Grafik 1. Bursa Eğitim. Doğrulama ve Test Kümelerine İlişkin Hata Performansları

Çanakkale ili için verilerin büyüklüğünden dolayı MATLAB programı Çanakkale modeli için 9 epoch kadar eğitimini yapmış olup en iyi sonucu 3'üncü iterasyonda en iyi eğitim olarak 0.033569 değerine varılmıştır.




Grafik 2 .Çanakkale Eğitim. Doğrulama ve Test Kümelerine İlişkin Hata Performansları

- **Gradient:** Yakın bir noktadaki fonksiyon değerine doğrusal olarak yaklaşmak için belirli bir noktadaki gradyanı kullanılır ve bu gradyan değerleri gerçek değerler ile karşılaştırılarak grafiği çizilir. Bir fonksiyonun değerini ve belirli bir noktadaki türevin eğimi biliniyorsa, o zaman bu bilgi fonksiyonun yakın bir

noktadaki deęerini tahmin etmek iin kullanılır. Gradient deęerleri (-1) ile (0.5) arasındaki sonuçlar olumlu olarak deęerlendirilmektedir.


- **Validation Checks(Doęrulama Kontrolleri):** Test verisi ve eęitim modelleri arasındaki uyumu kontrol etmektedir.

Bursa ve anakkale illerine ait eęitilen verilerin grafikleri ařaęıdaki gibidir. Grafik 3'te verilen Bursa eęitim grafięinde 1000 olarak seilen iterasyon sayısında 12 iterasyonda en iyi eęitim grafięi elde edilmiř olup sırası ile gradyan. Mu ve doęrulama kontrol grafikleri izdirilir.




Grafik 3. Bursa Eęitim Grafięi

Grafik 4'te verilen anakkale eęitim grafięinde 1000 olarak seilen iterasyon sayısında 9 iterasyonda en iyi eęitim grafięi elde edilmiř olup sırası ile gradyan. Mu ve doęrulama kontrol grafikleri izdirilmiřtir.




Grafik 4. Çanakkale Eğitim Grafiği

Lag yani uzunluk x ekseninde yer alırken y ekseninde korelasyon değerleri yer almaktadır. Grafik 5'te Bursa iline ait hata verilerinin otomatik korelasyonunu vermektedir ve hata verilerindeki örnek sayısı bölünmesi "ortalama" olduğu gözlenmiştir. Diğer bir deyişle ise otokorelasyon olarakta bilinmektedir. Otokorelasyon; zaman serisindeki hata terimlerinin a periyodundaki hata ile b zamanındaki periyodun i hataları ile ilişkisidir. Güven aralığını(kırmızı kesikli çizgi) %95 olarak otomatik olarak belirlenmektedir ve simetrik olmasının sebebi pozitif gecikme ve negatif gecikme tarafından aynı bilgilere sahip olmasıdır. Yani buradaki grafikten görüldüğü üzere Bursa ilinin %95 güven aralığının hata verileri ile normal olarak dağıldığı sonucuna varılmıştır.



Grafik 5. Bursa Hata Korelasyon

Çanakkale iline aitte hata korelasyon oranı otomatik olarak seçilmiş olan %95 güven aralığına göre hata verileri ile normal olarak dağıldığı sonucuna varılmıştır.




Grafik 6. Çanakkale Hata Korelasyon

Hata histogram, verilerinin eğitilmesi hakkında daha fazla bilgi elde etmek için kullanılan bir araçlardan birisidir. Histogram grafiği aykırı değerlerin en iyi göstergesi olarak da bilinmektedir.


Grafik 7’de Bursa iline ait. Grafik 8’de Çanakkale iline ait hataların histogram grafiği görülmektedir. Grafikte yer alan mavi ile gösterilen çubuklar eğitim verilerini, yeşil çubuk doğrulama verilerini ve kırmızı çubuk ise test verilerini göstermektedir.

Grafik 7’de Bursa iline ait verilerine ait görülen uyumsuzluğun nedeni veri çokluğundan kaynaklanan daha kötü veri noktaları olan hataların göstergesidir. Bursa ilinin hata oranları -0.573 ile 0.566 arasındadır ve 1818 verinin 400 adeti örnek olarak ele alınmış olup hata 0.03403 olarak bulunmuştur.




Grafik 7. Bursa İlinin Hata Histogram

Çanakkale ilinin hata oranları Grafik 8’de de görüldüğü üzere -0.646 ile 0.521 arasındadır ve 1818 verinin 480 adeti örnek olarak ele alınmış olup hata 0.05433 olarak bulunmuştur.




Grafik 8. Çanakkale İlinin Hata Histogram

Bursa iline ait zaman serisi Grafik 9’da görülmektedir. NAR modelinin eğitim doğrulama ve test sürecindeki çıktılarının sinir ağı grafiğidir. İkinci yani error grafiği ise MSE grafiğidir.




Grafik 9. Bursa İline Ait Zaman Serisi Grafiği

Çanakkale iline ait Zaman Serisi grafik 10’da görülmektedir. NAR modelinin eğitim doğrulama ve test sürecindeki çıktılarının sinir ağı grafiğidir. İkinci yani error grafiği ise MSE grafiğidir.




Grafik 10.Çanakkale İline Ait Zaman Serisi Grafiği

Regresyon; iki veya çok değişkenli modellerde bağımlı değişkenin x(nispi nem, toplam yağış, saatlik güneşlenme süresi, buharlaşma ve aktüel basınç); bağımsız değişken y(günlük/saatlik güneş ışıınımı) arasındaki ilişkinin matematik bir fonksiyonla ortaya konmasıdır. Grafik 11’de Bursa ilinin eğitim, doğrulama, test ve bütün olarak incelenen regresyon değerleri bulunmaktadır. Grafiğe baktığımızda eğitim verilerinin %78 oranında açıkladığı, doğrulama verilerinin %83 oranında açıklanırken; test verileri ise %82 oranında açıklamıştır. Bütün olarak modelimiz bağımlı ve bağımsız değişkenler arasındaki ilişkiyi %80 oranında açıklamıştır.



Grafik 11. Bursa İlinin Eğitim Regresyonu

Grafik 12’de Çanakkale ilinin eğitim, doğrulama, test ve bütün olarak incelenen regresyon değerleri bulunmaktadır. Grafiğe baktığımızda eğitim verilerinin %84, doğrulama verilerinin %88, test verilerinin ise %81 oranında açıklamıştır. Bütün olarak modelimiz bağımlı ve bağımsız değişkenler arasındaki ilişkiyi %84 oranında açıklamıştır.



Grafik 12. Çanakkale İlinin Eğitim Regresyonu

Tablo 4'te Bursa ve Çanakkale illerine ait verilerin Bayesian Regularization, Levenberg-Marquardt ve Scaled Conjugate Gradient yöntemleriyle MATLAB programıyla hesaplanmış hata değerleri görülmektedir. Tüm yöntemlerin değerleri karşılaştırıldığında Bursa ili için en iyi sonucu veren Bayesian Regularization yöntemi, Çanakkale ili için ise en iyi sonucu veren Levenberg-Marquardt yöntemi olmuştur.

Tablo 4. Çanakkale ve Bursa Hata Değerlerinin Karşılaştırması

Yöntem	Çanakkale			Bursa		
	Levenberg-Marquardt	Bayesian Regularization	Scaled Conjugate Gradient	Levenberg-Marquardt	Bayesian Regularization	Scaled Conjugate Gradient
MSE	0.0293	0.0295	0.0295	0.0253	0.0242	0.0282
RMSE	0.1711	0.1718	0.1717	0.1589	0.1556	0.1681
MAE	0.1264	0.1269	0.1274	0.1136	0.1104	0.1187

3.3. Makine Öğrenmesi Analiz Sonuçları

Bursa ve Çanakkale veri setlerindeki güneş ışıınının (y), sınıf etiketlerine ayrıştırılması Tablo 8'de gösterilmektedir. Güneş ışıınının, ampirik ölçümlerde 0 ile 1 arasında değişmektedir. Bu veri setlerini bir sınıflandırma problemine dönüştürmek için belirli ölçüm aralıklarının sınıf etiketlerine dönüştürülmesi gerekmektedir.

Tablo 5. Güneş Radyasyonunun Sınıf Etiketlerine Ayrıştırılması

Sınıf ID	Radyasyon Aralığı
1	$0 \leq y < 0.1$
2	$0.1 < y < 0.2$
3	$0.2 < y < 0.3$
4	$0.3 < y < 0.4$
5	$0.4 < y < 0.5$
6	$0.5 < y < 0.6$
7	$0.6 < y < 0.7$
8	$0.7 < y < 0.8$
9	$0.8 < y < 0.9$
10	$0.9 < y \leq 1.0$

Bursa ilinin yapay zeka yöntemlerinden olan makine öğrenmesinin sonuçlarına göre Tablo 8'de gösterilmiştir.

Tablo 6. Bursa ve Çanakkale Makine Öğrenmesi Algoritmasının Karşılaştırması

	Bursa	Çanakkale
Yöntemler	Doğruluk	
Karar Ağaçları	0,8731**	0,8585**
Standartlaştırılmış Değişken Mesafeler	0,8576	0,8368
En Yakın Komşu Algoritması	0,8613	0,8545
Naive Bayes	0,8648	0,8517
	Duyarlılık	
Karar Ağaçları	0,3543**	0,2885**
Standartlaştırılmış Değişken Mesafeler	0,2857	0,2134
En Yakın Komşu Algoritması	0,2992	0,2686
Naive Bayes	0,3382	0,2305
	Belirginlik	
Karar Ağaçları	0,9279**	0,9202**
Standartlaştırılmış Değişken Mesafeler	0,9198*	0,9095*
En Yakın Komşu Algoritması	0,9214*	0,9183*
Naive Bayes	0,9231*	0,9159*
	Hassaslık	
Karar Ağaçları	0,3751**	0,3063**
Standartlaştırılmış Değişken Mesafeler	0,2509	0,1714
En Yakın Komşu Algoritması	0,2973	0,2742
Naive Bayes	0,361	0,249
	F-skor	
Karar Ağaçları	0,3511**	0,2842**
Standartlaştırılmış Değişken Mesafeler	0,2544	0,1684
En Yakın Komşu Algoritması	0,2957	0,2691
Naive Bayes	0,2923	0,1866

*Makine Öğrenmesi Ölçeklendirme

** Makine Öğrenmesi Sınıflama

Tablo 8’de Bursa ve Çanakkale veri setlerinin makine öğrenmesi analiz verilmiştir. Analiz sonuçları bakıldığında sonuçlar birbirlerine yakın çıkmıştır. En iyi sınıf modellemesini karar ağaçları algoritması ile ulaşılmıştır.

Tablo 7. $0 \leq y < 0.1$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,9032	0,4474	0,9564	0,5568	0,4887
Standartlaştırılmış Değişken Mesafeler	0,8377	0,4789	0,8796	0,3152	0,3702
En Yakın Komşu Algoritması	0,8883	0,4842	0,9355	0,4739	0,4773
Naive Bayes	0,9136	0,1842	0,9988	0,9418	0,3045

Doğruluk ölçütünün sonuçları 0,9136 değer ile en iyi sonucu NB algoritması, duyarlılık ölçütünün sonuçları 0,4842 değer ile en iyi sonucu KNN algoritması, belirginlik ölçütünün sonuçları 0,9988 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,3063 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,4887 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 8. $0.1 \leq y < 0.2$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0.8124	0,4244	0,8825	0,3897	0,4052
Standartlaştırılmış Değişken Mesafeler	0,7998	0,5176	0,8506	0,3878	0,4418
En Yakın Komşu Algoritması	0,8229	0,3887	0,9013	0,4178	0,4024
Naive Bayes	0,8091	0,5759	0,8513	0,4225	0,4648

Doğruluk ölçütünün sonuçları 0,8229 değer ile en iyi sonucu KNN algoritması, duyarlılık ölçütünün sonuçları 0,5759 değer ile en iyi sonucu NB algoritması, belirginlik ölçütünün sonuçları 0,9013 değeri ile en iyi sonucu KNN algoritması, hassaslık ölçütünün sonuçları 0,4225 değer ile en iyi sonucu NB algoritması ve F-Skor ölçütünün sonuçları 0,4648 değer ile en iyi sonucu NB algoritmasıdır.

Tablo 9. $0.2 \leq y < 0.3$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,7877	0,3464	0,8759	0,3564	0,3506
Standartlaştırılmış Değişken Mesafeler	0,7921	0,1485	0,9208	0,2764	0,1925
En Yakın Komşu Algoritması	0,7642	0,3005	0,8568	0,2973	0,2976
Naive Bayes	0,7783	0,2306	0,8878	0,2974	0,2485

Doğruluk ölçütünün sonuçları 0,7921 değer ile en iyi sonucu SVD algoritması, duyarlılık ölçütünün sonuçları 0,3464 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9208 değeri ile en iyi sonucu SVD algoritması, hassaslık ölçütünün sonuçları 0,3564 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları

0,3506 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 10. $0.3 \leq y < 0.4$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8075	0,3335	0,8807	0,3006	0,3155
Standartlaştırılmış Değişken Mesafeler	0,8174	0,1318	0,9232	0,1955	0,1548
En Yakın Komşu Algoritması	0,7849	0,2303	0,8705	0,2174	0,2232
Naive Bayes	0,7536	0,4855	0,7952	0,2694	0,3456

Doğruluk ölçütünün sonuçları 0,8174 değer ile en iyi sonucu SVD algoritması, duyarlılık ölçütünün sonuçları 0,4855 değer ile en iyi sonucu NB algoritması, belirginlik ölçütünün sonuçları 0,9232 değeri ile en iyi sonucu SVD algoritması, hassaslık ölçütünün sonuçları 0,3006 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,3456 değer ile en iyi sonucu NB algoritmasıdır.

Tablo 11. $0.4 \leq y < 0.5$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8741	0,1925	0,9337	0,2359	0,2026
Standartlaştırılmış Değişken Mesafeler	0,8740	0,1025	0,9414	0,1362	0,1153
En Yakın Komşu Algoritması	0,8669	0,1446	0,9300	0,1561	0,1487
Naive Bayes	0,9032	0,0480	0,9779	0,1528	0,0699

Doğruluk ölçütünün sonuçları 0,9032 değer ile en iyi sonucu NB algoritması, duyarlılık ölçütünün sonuçları 0,1925 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9779 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,2359 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,2026 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 12. $0.5 \leq y < 0.6$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8856	0,1729	0,9502	0,2241	0,1881
Standartlaştırılmış Değişken Mesafeler	0,8388	0,2378	0,8932	0,1731	0,1981
En Yakın Komşu Algoritması	0,8807	0,2581	0,9370	0,2782	0,2647
Naive Bayes	0,8696	0,1996	0,9304	0,2055	0,1718

Doğruluk ölçütünün sonuçları 0,8856 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,2581 değer ile en iyi sonucu KNN algoritması, belirginlik ölçütünün sonuçları 0,9502 değeri ile en iyi sonucu DT algoritması, hassaslık ölçütünün sonuçları 0,2782 değer ile en iyi sonucu KNN algoritması ve F-Skor ölçütünün sonuçları 0,2647 değer ile en iyi sonucu KNN algoritmasıdır.

Tablo 13. $0.6 \leq y < 0.7$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8663	0,3687	0,9196	0,3302	0,3437
Standartlaştırılmış Değişken Mesafeler	0,8713	0,0627	0,9580	0,1348	0,0844
En Yakın Komşu Algoritması	0,8526	0,2329	0,9190	0,2364	0,2340
Naive Bayes	0,8851	0,1706	0,9617	0,3630	0,2104

Doğruluk ölçütünün sonuçları 0,8851 değer ile en iyi sonucu NB algoritması, duyarlılık ölçütünün sonuçları 0,3687 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9617 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,3630 değer ile en iyi sonucu NB algoritması ve F-Skor ölçütünün sonuçları 0,3437 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 14. $0.7 \leq y < 0.8$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8806	0,3391	0,9309	0,3089	0,3153
Standartlaştırılmış Değişken Mesafeler	0,8757	0,2606	0,9327	0,2721	0,2634
En Yakın Komşu Algoritması	0,8691	0,2994	0,9218	0,2627	0,2784
Naive Bayes	0,8751	0,2791	0,9303	0,2992	0,2761

Doğruluk ölçütünün sonuçları 0,8806 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,3391 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9327 değeri ile en iyi sonucu SVD algoritması, hassaslık ölçütünün sonuçları 0,3089 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,3153 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 15. $0.8 \leq y < 0.9$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,9285	0,6387	0,9555	0,5817	0,6014
Standartlaştırılmış Değişken Mesafeler	0,8894	0,6774	0,9092	0,4066	0,5043
En Yakın Komşu Algoritması	0,9015	0,3742	0,9507	0,4184	0,3926
Naive Bayes	0,8872	0,5290	0,9206	0,3811	0,4412

Doğruluk ölçütünün sonuçları 0,9285 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,6774 değer ile en iyi sonucu SVD algoritması, belirginlik ölçütünün sonuçları 0,9555 değeri ile en iyi sonucu DT algoritması, hassaslık ölçütünün sonuçları 0,5817 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,6014 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 16. $0.9 \leq y < 1.0$ Sınıf Aralığının Bursa İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,9857	0,2802	0,9944	0,4667	0,3010
Standartlaştırılmış Değişken Mesafeler	0,9802	0,2402	0,9894	0,2119	0,2205
En Yakın Komşu Algoritması	0,9830	0,2811	0,9916	0,2157	0,2391
Naive Bayes	0,9741	0,6800	0,9777	0,2778	0,3902

Doğruluk ölçütünün sonuçları 0,9857 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,6800 değer ile en iyi sonucu NB algoritması, belirginlik ölçütünün sonuçları 0,9944 değeri ile en iyi sonucu DT algoritması, hassaslık ölçütünün sonuçları 0,4677 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,3902 değer ile en iyi sonucu NB algoritmasıdır.

Tablo 17. $0 \leq y < 0.1$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları (Decision Tree)	0,8966	0,2683	0,9416	0,2453	0,2456
Standartlaştırılmış Değişken Mesafeler	0,8471	0,3127	0,8856	0,1609	0,2114
En Yakın Komşu Algoritması	0,8545	0,2686	0,9183	0,2742	0,2692
Naive Bayes	0,8517	0,2305	0,9159	0,2490	0,1866

Doğruluk ölçütünün sonuçları 0,8966 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,3127 değer ile en iyi sonucu SVD algoritması, belirginlik ölçütünün sonuçları 0,9416 değeri ile en iyi sonucu DT algoritması, hassaslık ölçütünün sonuçları 0,2742 değer ile en iyi sonucu KNN algoritması ve F-Skor ölçütünün sonuçları 0,2692 değer ile en iyi sonucu KNN algoritmasıdır.

Tablo 18. $0.1 \leq y < 0.2$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8196	0,3568	0,8765	0,2680	0,3046
Standartlaştırılmış Değişken Mesafeler	0,8223	0,3015	0,8864	0,2494	0,2690
En Yakın Komşu Algoritması	0,8476	0,2864	0,9166	0,2972	0,2907
Naive Bayes	0,7706	0,5327	0,7999	0,2472	0,3358

Doğruluk ölçütünün sonuçları 0,8476 değer ile en iyi sonucu KNN algoritması, duyarlılık ölçütünün sonuçları 0,5327 değer ile en iyi sonucu NB algoritması, belirginlik ölçütünün sonuçları 0,9166 değeri ile en iyi sonucu KNN algoritması, hassaslık ölçütünün sonuçları 0,2972 değer ile en iyi sonucu KNN algoritması ve F-Skor ölçütünün sonuçları 0,3358 değer ile en iyi sonucu NB algoritmasıdır.

Tablo 19. $0.2 \leq y < 0.3$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8152	0,3026	0,8924	0,3001	0,2935
Standartlaştırılmış Değişken Mesafeler	0,7948	0,2395	0,8785	0,2291	0,2337
En Yakın Komşu Algoritması	0,8069	0,2853	0,8854	0,2736	0,2770
Naive Bayes	0,8603	0,0800	0,9778	0,3233	0,1249

Doğruluk ölçütünün sonuçları 0,8603 değer ile en iyi sonucu NB algoritması, duyarlılık ölçütünün sonuçları 0,3026 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9778 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,3233 değer ile en iyi sonucu NB algoritması ve F-Skor ölçütünün sonuçları 0,2935 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 20. $0.3 \leq y < 0.4$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8141	0,2372	0,8915	0,2385	0,2307
Standartlaştırılmış Değişken Mesafeler	0,8366	0,1814	0,9245	0,2413	0,2052
En Yakın Komşu Algoritması	0,8267	0,2744	0,9008	0,2719	0,2727
Naive Bayes	0,7707	0,4419	0,8148	0,2511	0,3102

Doğruluk ölçütünün sonuçları 0,8366 değer ile en iyi sonucu SVD algoritması, duyarlılık ölçütünün sonuçları 0,4419 değer ile en iyi sonucu NB algoritması, belirginlik ölçütünün sonuçları 0,9245 değeri ile en iyi sonucu SVD algoritması, hassaslık ölçütünün sonuçları 0,2719 değer ile en iyi sonucu KNN algoritması ve F-Skor ölçütünün sonuçları 0,3102 değer ile en iyi sonucu NB algoritmasıdır.

Tablo 21. $0.4 \leq y < 0.5$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8889	0,0520	0,9658	0,1486	0,0744
Standartlaştırılmış Değişken Mesafeler	0,8845	0,0914	0,9574	0,1657	0,1169
En Yakın Komşu Algoritması	0,8603	0,1570	0,9249	0,1571	0,1562
Naive Bayes	0,8707	0,1385	0,9381	0,1707	0,1218

Doğruluk ölçütünün sonuçları 0,8889 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,1570 değer ile en iyi sonucu KNN algoritması, belirginlik ölçütünün sonuçları 0,9658 değeri ile en iyi sonucu DT algoritması, hassaslık ölçütünün sonuçları 0,1707 değer ile en iyi sonucu NB algoritması ve F-Skor ölçütünün sonuçları 0,1562 değer ile en iyi sonucu KNN algoritmasıdır.

Tablo 22. $0.5 \leq y < 0.6$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8889	0,1284	0,9603	0,2255	0,1568
Standartlaştırılmış Değişken Mesafeler	0,8791	0,0321	0,9585	0,0751	0,0443
En Yakın Komşu Algoritması	0,8537	0,1417	0,9206	0,1416	0,1404
Naive Bayes	0,8999	0,0452	0,9801	0,1437	0,0677

Doğruluk ölçütünün sonuçları 0,8999 değer ile en iyi sonucu NB algoritması, duyarlılık ölçütünün sonuçları 0,1417 değer ile en iyi sonucu KNN algoritması, belirginlik ölçütünün sonuçları 0,9801 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,2255 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,1568 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 23. $0.6 \leq y < 0.7$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0.8515	0,3063	0,9157	0,3106	0,3031
Standartlaştırılmış Değişken Mesafeler	0,8526	0,0623	0,9459	0,1204	0,0801
En Yakın Komşu Algoritması	0,8416	0,2248	0,9145	0,2367	0,2285
Naive Bayes	0,8735	0,0629	0,9693	0,2595	0,0898

Doğruluk ölçütünün sonuçları 0,8735 değer ile en iyi sonucu NB algoritması, duyarlılık ölçütünün sonuçları 0,3063 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9693 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,3106 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,3031 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 24. $0.7 \leq y < 0.8$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0,8372	0,3091	0,9099	0,3322	0,3164
Standartlaştırılmış Değişken Mesafeler	0,8295	0,0727	0,9337	0,1226	0,0903
En Yakın Komşu Algoritması	0,8256	0,2773	0,9011	0,2748	0,2750
Naive Bayes	0,8284	0,1455	0,9225	0,1722	0,1196

Doğruluk ölçütünün sonuçları 0,8372 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,3091 değer ile en iyi sonucu DT algoritması, belirginlik ölçütünün sonuçları 0,9337 değeri ile en iyi sonucu SVD algoritması, hassaslık ölçütünün sonuçları 0,3322 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,3164 değer ile en iyi sonucu DT algoritmasıdır.

Tablo 25. $0.8 \leq y < 0.9$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0.8042	0,4651	0,8598	0,3561	0,4014
Standartlaştırılmış Değişken Mesafeler	0,7827	0,1995	0,8783	0,2099	0,2037
En Yakın Komşu Algoritması	0,8311	0,4261	0,8976	0,4108	0,4166
Naive Bayes	0,7508	0,6208	0,7720	0,3133	0,3839

Doğruluk ölçütünün sonuçları 0,8311 değer ile en iyi sonucu KNN algoritması, duyarlılık ölçütünün sonuçları 0,6208 değer ile en iyi sonucu NB algoritması, belirginlik ölçütünün sonuçları 0,8976 değeri ile en iyi sonucu KNN algoritması, hassaslık ölçütünün sonuçları 0,4108 değer ile en iyi sonucu KNN algoritması ve F-Skor ölçütünün sonuçları 0,4166 değer ile en iyi sonucu KNN algoritmasıdır.

Tablo 26. $0.9 \leq y < 1.0$ Sınıf Aralığının Çanakkale İlinin Makine Öğrenmesinin Karşılaştırılması

Yöntemler /Metrikler	Doğruluk	Duyarlılık	Belirginlik	Hassaslık	F-Skor
Karar Ağaçları	0.9692	0,4593	0,9886	0,6381	0,5159
Standartlaştırılmış Değişken Mesafeler	0,8394	0,6418	0,8469	0,1404	0,2299
En Yakın Komşu Algoritması (K-Nearest Neighbor)	0,9615	0,4000	0,9829	0,4800	0,4303
Naive Bayes	0,9648	0,1890	0,9943	0,4433	0,2377

Doğruluk ölçütünün sonuçları 0,9692 değer ile en iyi sonucu DT algoritması, duyarlılık ölçütünün sonuçları 0,6418 değer ile en iyi sonucu SVD algoritması, belirginlik ölçütünün sonuçları 0,9943 değeri ile en iyi sonucu NB algoritması, hassaslık ölçütünün sonuçları 0,6381 değer ile en iyi sonucu DT algoritması ve F-Skor ölçütünün sonuçları 0,5159 değer ile en iyi sonucu DT algoritmasıdır.

SONUÇ

Yaşadığımız yüzyılda sanayileşme, nüfus artışı, yakıt kullanımı ve kentleşme gibi çevreye zarar veren faktörlerin etkisiyle çevre kirliliği gün geçtikçe artmaktadır. Çevre kirliliğinin en önemli nedenlerinden biri olan nüfus artışı toplumsal taleplerin değişmesi ve ihtiyaçların artması neden olmakla beraber arzında artmasını zorunlu hale getirmiştir. Özellikle sanayi devriminde ham madde temininde ve üretim esnasında fosil kaynaklı enerji kullanımı oldukça artmıştır. Fosil kaynaklarının kullanımının artması toprak, su ve hava kirliliğine sebep olmakta, çevre açısından da olumsuz etkiler ortaya çıkarmaktadır. Ortaya çıkan olumsuz etkilerde iklim değişikliği, küresel ısınma ve kaynak kıtlığına sebep olmaktadır. Enerji kaynaklarının kıt olması ve aynı zamanda üretilirken çevreye vermiş olduğu kirlilikten dolayı yenilenebilir enerji kaynaklarının kullanımı teşvik edilmeye başlanılmıştır.

Yenilenebilir enerji doğal kaynaklardan elde edilen doğal çevreden sürekli veya tekrarlamalı olarak ulaşılan, sürdürülebilir ve kıt olmayan enerji kaynağıdır. Yenilenebilir enerji, fosil yakıtları gibi üretim esnasında CO_2 gaz salınımı olmadığından dolayı çevre kirliliğine, iklim değişikliğine ve küresel ısınmaya yol açmamaktadır. Ayrıca dünyayla birlikte ülkemizde de artışa geçen enerji ihtiyacına yönelik, çok yüksek fiyatlara ithal ettiğimiz fosil enerji kaynaklarına alternatif olarak önemli bir pay almaktadır. Yenilenebilir enerji kaynaklarının kullanımı ile birlikte yerli enerji üretimine geçişin, çevre kirliliğini en aza indirecek ve sosyo-ekonomik bakımından büyük bir atılım ve düzenleme sağlanabilecektir. Yenilenebilir enerji kaynaklarının en önemlisi ve büyük enerji potansiyelini bünyesinde bulunduran doğrudan veya dolaylı tüm enerji kaynaklarının ana kaynağı güneştir.

Güneş enerjisi, evrende en çok bulunan yenilenebilir enerji kaynağı olmasının yanı sıra çevre dostu, temiz, sınırsız ve işletme maliyetleri düşük bir enerji kaynağıdır. Ülkelerin gelişimi, enerjiye olan arz ve talebin artışıyla yenilenemez enerji kaynaklarının tükenmesinden dolayı güneş enerjisi kullanımı gün geçtikçe rağbet gören bir enerji türü konumundadır. Bu kapsamda yapılan girişimler, çalışmalar insan yararına olan atılımlar güneş enerjisinin vazgeçilemez bir konumda olduğunu göstermektedir. Güneş enerjisinin potansiyelini belirlemek için yapılan çalışmalarda güneş ışıınım şiddetinin miktarı önemli bir parametre olarak karşımıza çıkmaktadır.

Bu çalışmanın amacı, Bursa ve Çanakkale illerine ait 2015-2019 yılları arasında günlük/saatlik güneş ışınlamı verileri kullanılarak yapay sinir ağılarıyla tahminleme ve makine öğrenmesi algoritmasıyla sınıflama yapmaktır. Modele dâhil edilen 1818 adet verinin istatistik analizleri MATLAB paket programı aracılığıyla yapılmıştır. Burada değişkenler toplam yağış, nispi nem, buharlaşma saatlik, güneşlenme süresi ve aktüel basınç olarak belirlenmiştir.

Yapılan analize göre; Çanakkale ilinin YSA analizine ait eğitim verileri %84 Bursa ilinin eğitim verileri %78 oranında açıkladığı görülmektedir. Çanakkale ilinin doğrulama verilerinin sonucu %83 oranında açıklarken, Bursa ilinin doğrulama sonucu ise %88 oranında gerçekleşmiştir. Çanakkale ilinin test verileri ise %82 oranında açıklarken, Bursa ilinin test verileri ise %81 oranında olmuştur.

Hata değerlerine göre incelendiğinde ise; Bursa ilinin göre YSA' da kullanılan Bayesian Regularizasyon, Levenberg-Marquardt ve Scaled Conjugate Gradient yöntemleri denenmiş olup MSA değeri 0,0242, RMSE değeri 0,1556 ve MAE değeri ise 0,1104 ile sonuca Bayesian Regularizasyon yöntemi ve Çanakkale iline göre Bayesian Regularizasyon, Levenberg-Marquardt ve Scaled Conjugate Gradient yöntemleri göre MSE değeri 0,0293, RMSE değeri 0,1711 MAE değeri ise 0,1264 ile Levenberg-Marquardt yöntemi vermiştir. Aynı bölge de bulunan illerin sonuçları birbirine yakın çıkmıştır ve yapılan araştırmada YSA tahminleme tekniklerinin güneş ışınlamı tahmini yapılırken başarı ile kullanılabileceği sonucuna ulaşılmıştır.

Makine öğrenmesi algoritması uygulanırken güneş ışınlamı, ampirik ölçümlerde 0 ile 1 arasında değiştiğinden dolayı verileri bir sınıflama problemine dönüştürmek için belirli ölçüm aralıkları sınıf etiketlerine çevrilmiştir. Dönüştürülen sınıf etiketine göresınıflama analizlerinden KNN, NB, SVD ve DT yöntemleri kullanılmıştır. Analiz sonuçlarına göre; Bursa ilinde sınıflandırma da doğruluk ölçütü ile en verimli sonuca ulaşılmıştır ve DT algoritması ile sınıflandırma yapılmıştır. Çanakkale verilerinin sınıflandırılmasında ise belirginlik ölçütü ile daha iyi sınıflama yapıp DT algoritması ile ulaşılmıştır. Bu sonuçlar doğrultusunda, Çanakkale ve Bursa güneş ışınlamı verilerinde makine öğrenmesi algoritmasının sınıflama yöntemlerinden DT algoritmasıyla en iyi sonuca ulaşılmıştır.

Bu bağlamda Bursa ve Çanakkale illerimiz ne kadar aynı bölge de bulunsalar da aynı yöntemle aynı sonuçlara ulaşamamıştır. Bu doğrultuda enlem, boylam, deniz

seviyesi, güneş ışıının geliş açısı, toprak türü gibi değişkenler de güneş ışıını üzerinde önemli bir rol oynadığı sonucuna varılabilir. Ayrıca veriler saatlik veri olarak alındığından dolayı bazı saatlerde ölçümlerin eksik olması da etki etmektedir. Bundan sonraki çalışmalarda bu eksikliklerin giderilmesiyle daha net sonuçlar elde edilebilecektir.



KAYNAKÇA

- Ağış, Ö., Aydın, Y., Armağan, T. Y., & Kılıkış, B. (2020). **Hidrolojik Enerji**. Retrieved from <http://kojenturk.org/tr/hidrolik-enerji-87>
- Akar, A. (2016). **Bir Güneş Enerjisi Santralinin Kurulumu ve Performansının Analizi**. Fırat Üniversitesi. <https://doi.org/10.1017/CBO9781107415324.004>
- Alkan, M. A. (2017). **Makine Öğrenimi Nedir ?**, 2017.
- Alpaydın, E. (2014). **Introduction to Machine Learning**. London, England: The MIT Press. Retrieved from [https://dl.matlabiyar.com/siavash/ML/Book/Ethem Alpaydin-Introduction to Machine Learning-The MIT Press \(2014\).pdf](https://dl.matlabiyar.com/siavash/ML/Book/Ethem%20Alpaydin-Introduction%20to%20Machine%20Learning-The%20MIT%20Press%20(2014).pdf)
- Altunkaynak, A., & Ensar Başakin, E. (2018). **Zaman Serileri Kullanılarak Nehir Akım Tahmini ve Farklı Yöntemlerle Karşılaştırılması**. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(1), 92–101. <https://doi.org/10.18185/erzifbed.339781>
- Arslan, G., Bayhan, B. ve, & Yaman, K. (2019). **Türkiye İçin Ölçülen Global Güneş Işınımının Yapay Sinir Ağları ile Tahmin Edilmesi ve Yaygın Işınım Modelleri İle Karşılaştırılması**. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(1), 17. <https://doi.org/10.29109/gujsc.419473>
- Ataseven, B. (2013). **Yapay Sinir Ağları İle Öngörü Modellemesi**. *Öneri Dergisi*. <https://doi.org/10.14783/od.v10i39.1012000311>
- Atçıl, M. (2020). **Enerji Kaynakları ve Yöntemi**, 122.
- Avuçlu, E., & Elen, A. (2020). **Makine Öğrenme Algoritmasına Genel Bakış**. In D. Ö. Ü. E. Avuçlu & D. Ö. Ü. D. Ekmekci (Eds.), *Geleceğin Dünyasında Bilimsel ve Mesleki Çalışmalar 2020 Bilgisayar Mühendisliği/1* (Birinci Ba, pp. 36–37). BURSA/Osmangazi.
- Bakırcı, K. (2009). **Yatay Yüzeye Gelen Anlık Global Güneş Işınım Tahmini için Basit Bir Hesaplama Metodu**. *Isı Bilimi ve Tekniği Dergisi*, 29, 53–58. [https://doi.org/ISSN 1300-3615](https://doi.org/ISSN%201300-3615)
- Bıyık, İ. (2010). **Hava Kirliliğinin Yapay Zeka Teknikleri ile Belirlenmesi**.
- Bou-Rabee, M., Sulaiman, S. A., Saleh, M. S., & Marafi, S. (2017). **Using artificial neural networks to estimate solar radiation in Kuwait**. *Renewable and Sustainable Energy Reviews*, 72, 434–438. <https://doi.org/10.1016/J.RSER.2017.01.013>

- Bozyiğit, B. Ş., & Tarhan, Ç. (2020). **Makine Öğrenmesi Yöntemleri Kullanarak Sosyal Medyada Marka İtibar Analizi.**
- Büber, E. (2018). **Makine Öğrenmesi Nedir?** Retrieved December 9, 2021, from <https://medium.com/@EbubekirBbr/makine-öğrenmesi-nedir-dbb55d007da0>
- Caballero, R., Zarzalejo, L. F., Otero, Á., Piñuel, L., & Wilbert, S. (2018). **Short Term Cloud Nowcasting for a Solar Power Plant based on Irradiance Historical Data.** *Urnl of Computer Science & Technology*, 18(3), 186–192. <https://doi.org/10.24215/16666038.18.e21>
- Can, Ş., & Gerşil, M. (2018). **Manisa Pamuk Fiyatlarının Zaman Serisi Analizi Ve Yapay Sinir Ağı Teknikleri İle Tahminlenmesi Ve Tahmin Performanslarının Karşılaştırılması.** *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15. <https://doi.org/10.18657/yonveek.457761>
- Çelik, B. (2019). **Tüketici Tercihlerinin Yapay Sinir Ağları Yöntemiyle Tahmini: Perakende Sektörlerinde Bir Uygulama.** Manisa Celal Bayar Üniversitesi.
- Coskun, C., Koçyiğit, N., & Oktay, Z. (2016). **Yapay Sinir Ağları İle Pv Modül Yüzey Sıcaklığının Tahmini.** *Mugla Journal of Science and Technology*, 2(2), 15–15. <https://doi.org/10.22531/muglajsci.283611>
- Cover, TM ve Hart, P. (1967). **En Yakın Komşu Örüntü Sınıflandırması.** *IEEE Transactions on Information Theory*, s. 21-27. <https://doi.org/10.1109/TIT.1967.1053964>.
- Demir, İ. (2016). **Güneş Enerjisi ile Çalışan Bir Sistem Tasarlanarak Kömürlerin Kurutulması ve Kalitelerinin Artırılması.** İstanbul Üniversitesi.
- Deniz, E., & Atik, K. (2007). **Güneş Işınım Şiddeti Tahminlerinde Yapay Sinir Ağları ve Regresyon Analiz Yöntemleri Kullanımının İncelenmesi.** *Isı Bilimi ve Tekniği Dergisi*, 27(2), 15–20. <https://doi.org/ISSN 1300-3615>
- Dinçer, F. (2011). **Türkiye ' de Güneş Enerjisinden Elektrik Üretimi Potansiyeli - Ekonomik Analizi ve AB Ülkeleri.** *KSU Mühendislik Dergisi*, 14(1), 2011, 14(1), 8–17.
- Doğan, C. (2006). **Güneş Enerjisi Yardımıyla Gerçekleştirilen Isıtma Sistemlerinin Kocaeli Bölgesi İçin Uygulanabilirliğinin Araştırılması.** Marmara Üniversitesi.
- Doğan, M. (2019). **Güneş Enerjisi Santrallerinin İncelenmesi ve Verimlilik Analizi.** Sakarya Üniversitesi.
- Elen, A., & Avuçlu, E. (2020). **Makine Öğrenme Algoritmalarına Genel Bakış,** (May).

- Elen, A., & Avuçlu, E. (2021). **Standartlaştırılmış Değişken Mesafeler: Uzaklığa Dayalı Bir Makine Öğrenimi Yöntemi.** *Applied Soft Computing*, 98. <https://doi.org/10.1016/j.asoc.2020.106855>
- Elen, A., & Kamil Turan, M. (2019). Uluslararası Mühendislik Araştırma ve. *Geliştirme Dergisi International Journal of Engineering Research and Development UMAGD*, 11(1), 141. <https://doi.org/10.29137/umagd.498372>
- Emrahoğlu, N., & Yeğingil, İ. (2019). **Çukurova Üniversitesi'nde Ölçülen Güneş Işınım Verileri Analizi.** *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 34(2), 87–96. <https://doi.org/10.21605/CUKUROVAUMMF.608964>
- Erdil, A., & Arcaklioglu, E. (2013). **The prediction of meteorological variables using artificial neural network.** *Neural Computing and Applications*, 22(7–8), 1677–1683. <https://doi.org/10.1007/s00521-012-1210-0>
- Erenler, A. (2019). **KNN ve Yapay Sinir Ağları Kullanarak Sistem Etkinliği ve Kalite Kaybı Tahmini.** Retrieved from <https://avesis.cu.edu.tr/yonetilen-tez/1a763e41-fcbc-44b8-b4d7-5df1c4965ff3/knn-ve-yapay-sinir-aglari-kullanarak-sistem-etkinligi-ve-kalite-kaybi-tahmini>
- Ervural, B. Ç. (2018). **Yenilenebilir Enerji Planlaması İçin Bütünleşik Çok Amaçlı Bir Karar Modeli Önerisi.** İstanbul Teknik Üniversitesi. Retrieved from https://movisa.org.mx/images/NoBS_Report.pdf
- Eskin, N. (2006). **Türkiye'de Güneş Enerjisi Araştırma ve Geliştirme.** *Tesisat Mühendisliği Dergisi Sayı: 91, s. 74-82, 2006.* Retrieved from <https://studylibtr.com/doc/3487083/turkiye-de-gunes-enerjisi-arastirma-ve-gelistirme>
- Eyvazov, A. (2019). **Yapay Sinir Ağları İle Güneş Enerjisi Potansiyelinin Modellemesi ve Güneş Pilleri Verim Analizi.** İstanbul Aydın Üniversitesi.
- Fan, J., Wu, L., Zhang, F., Cai, H., Zeng, W., Wang, X., & Zou, H. (2019). **Empirical and machine learning models for predicting daily global solar radiation from sunshine duration: A review and case study in China.** *Renewable and Sustainable Energy Reviews*, 100, 186–212. <https://doi.org/10.1016/J.RSER.2018.10.018>
- Gabralı, D. (2019). **Yapay Sinir Ağları İle Rüzgar ve Güneş Enerjisi Potansiyelinin Modellemesi ve Dalgacık Dönüşümü İle Analizi.** İstanbul Üniversitesi.
- Gabralı, D., & Aslan, Z. (2020). **Güneş Enerjisi Potansiyelinin Çoklu Lineer Regresyon ve Yapay Sinir Ağları ile Modellenmesi.** *AURUM Mühendislik*

- Sistemleri ve Mimarlık Dergisi*, 4(1), 23–36. Retrieved from <https://dergipark.org.tr/tr/pub/ajesa/issue/55595/604289>
- Gala, Y., Fernández, Á., Díaz, J., & Dorronsoro, J. R. (2016). **Hybrid machine learning forecasting of solar radiation values.** *Neurocomputing*, 176, 48–59. <https://doi.org/10.1016/j.neucom.2015.02.078>
- Ghofrani, M., Azimi, R., & Youshi, M. (2019). **Pattern Recognition and Its Application in Solar Radiation Forecasting.** *Pattern Recognition - Selected Methods and Applications*, (January). <https://doi.org/10.5772/intechopen.83503>
- Göçgün, Ö. F., & Onan, A. (2021). **Amazon Ürün Değerlendirmeleri Üzerinde Derin Öğrenme/Makine Öğrenmesi Tabanlı Duygu Analizi Yapılması.** *European Journal of Science and Technology*, (24), 445–448. <https://doi.org/10.31590/ejosat.902674>
- Harrington, P. (2012). **Machine Learning in Action. Printed in the United States of America: MANNING Shelter Island.**
- Holzinger, A., Langs, G., Denk, H., Zatloukal, K., & Müller, H. (2019, July 1). **Causability and explainability of artificial intelligence in medicine.** *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. Wiley-Blackwell. <https://doi.org/10.1002/widm.1312>
- IBM. (2020). **IBM Cloud Education.** Retrieved from <https://www.ibm.com/tr-tr/cloud/learn/what-is-artificial-intelligence>
- İçel, Y. (2019). **Güneş Enerji Sistemlerinin Performans Tahmini İçin Yapay Sinir Ağları İle Modellemesi ve Verimliliğin İncelenmesi.** İnönü Üniversitesi.
- İlkılıç, C. (2003). Rüzgar Enerjisi ve Kullanımı. *Doğu Anadolu Bölge Araştırması*, 44.
- İnan, İ., Akbulut, İ., & Aslan, E. (2018). **Enerji Sorununun Çözümünde Yenilenemez ve Yenilenebilir Enerji Kaynaklarının Yeri ve Önemi.**
- İpek, B. (2019). **Anfıs ve Arıma Modelleri İle Endüstri 4.0 Verilerinin Karşılaştırılması.** Karadeniz Teknik Üniversitesi.
- İşler, B., & Kılıç, M. (2021). Yeni Medya Elektronik Dergisi » Makale » **Eğitimde Yapay Zekâ Kullanımı Ve Gelişimi**, 5(1), 1–11. Retrieved from <https://dergipark.org.tr/tr/pub/ejnm/issue/58097/738221>
- KA Baharin, HA Rahman, M. H. ve G. K. (2013). ISBN : 978-605-68882-0-5. In *IEEE Araştırma ve Geliştirme Öğrenci Konferansı* (pp. 191–197). <https://doi.org/10.1109/SCORED.2013.7002570>.

- Kanat, H. (2019). *Yenilenebilir Enerji Kaynaklarından Güneş Enerjisi Yatırımlarını Etkileyen Faktörler: Konya Güneş Enerjisi Yatırımları Analizi*. Selçuk Üniversitesi.
- Kapluhan, E. (2014). *Enerji Coğrafyası Açısından Bir İnceleme: Güneş Enerjisinin Dünya’ daki ve Türkiye’deki*. *İstanbul Üniversitesi Edebiyat Fakültesi Coğrafya Bölümü Coğrafya Dergisi*, 29.
- Kavas, H. G. (2019). *Türkiye Enerji Sektörünün Stratejik Konumu ve Yapay Sinir Ağı Modelleriyle Enerji Tüketiminin Tahmini*. Sivas Cumhuriyet Üniversitesi.
- Kaya, D. (2020). *Güneş Işınım Şiddetinin Akıllı Hibrit Yaklaşımlar İle Tahmini*. Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü. Retrieved from <http://acikkaynak.bilecik.edu.tr/xmlui/handle/11552/1767>
- Kaya, K., Şenel, M. C., & Koç, E. (2018). *Dünya’da ve Türkiye’de Yenilenebilir Enerji Kaynaklarının Değerlendirilmesi*, 7223(November 2017), 1–26. <https://doi.org/10.12739/NWSA.2018.13.3.2A0152.Kaya>
- Kaya, Ö. (2019). *Analysis Of Meteorological Data By Artificial Intelligence Techniques and Estimation Of Global Solar Radiation*.
- Kaynar, N. K. (2020). *Yenilenebilir Enerji Kaynaklarından Güneş Enerjisinin Amasya İlindeki Potansiyeli*. *Bilge International Journal of Science and Technology Research*, 4(2), 48–54. Retrieved from <https://dergipark.org.tr/tr/pub/bilgesci/issue/56891/711112>
- Khatib, T., Mohamed, A., Sopian, K., & Mahmoud, M. (2012). *Solar energy prediction for Malaysia using artificial neural networks*. *International Journal of Photoenergy*, 2012. <https://doi.org/10.1155/2012/419504>
- Kılıç, İ. H. (2016). *Türkiye’de Rüzgar Enerjisi Santralleri İçin Teşvik Uygulamaları ve Bilgisayra Programı İle İrdelenmesi*. ulusal tez merkezi. İstanbul Teknik Üniversitesi. Retrieved from file:///Users/andreataquez/Downloads/guia-plan-de-mejorainstitucional.pdf%0Ahttp://salud.tabasco.gob.mx/content/revista%0Ahttp://www.revistaalad.com/pdfs/Guias_ALAD_11_Nov_2013.pdf%0Ahttp://dx.doi.org/10.15446/revfacmed.v66n3.60060.%0Ahttp://www.cenetec
- Kır, E. G., & Güldal, V. (2020). *Antalya İli Aylık ve Yıllık Yağışlarının Zaman Serisi Modellemesi*. *SU VAKFI*, 1(0), 15.
- Kıymaz, Y. E. (2020). *Güneş Enerjisi Santrallerinden Derin Öğrenme Kullanılarak Elektrik Üretimi Tahmininin Yapılması*. ulusal tez merkezi.

- Krishna, P., & DE, H. S. (2005). **Naive-Bayes Classification Using Fuzzy Approach.** *Naive-Bayes Classification Using Fuzzy Approach. Third International Conference on Intelligent Sensing and Information Processing, Bangalore/India*, 61–64.
- Kurt, F. (2017). **Open Zeka Ofisi.** Retrieved from <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>
- Li, J., Ward, J. K., Tong, J., Collins, L., & Platt, G. (2016). **Machine learning for solar irradiance forecasting of photovoltaic system.** *Renewable Energy*, 90, 542–553. <https://doi.org/10.1016/j.renene.2015.12.069>
- Long, H., Zhang, Z., & Su, Y. (2014). **Analysis Of Daily Solar Power Prediction With Data-Driven Approaches.** *Applied Energy*, 126, 29–37. <https://doi.org/10.1016/j.apenergy.2014.03.084>
- Mackay, D. J. C. (1992). **Bayesian Interpolation.** *Neural Computation*, 4(3), 415–447. <https://doi.org/10.1162/neco.1992.4.3.415>
- Mengeş, H. O., & Sonmete, M. H. (2005). **Konya’da Aylık Ortalama Toplam Güneş Işınımının Tahmini İçin Mevcut Bazı Modellerin Karşılaştırılması.** *Tarım Makinaları Bilimi Dergisi*, 1(3), 237–244.
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2012). **Foundations of Machine Learning.** Retrieved from [https://d1rkab7tlqy5f1.cloudfront.net/EWI/Over de faculteit/Afdelingen/Intelligent Systems/Pattern Recognition Laboratory/PR/Reading Group/Foundations_of_Machine_Learning.pdf](https://d1rkab7tlqy5f1.cloudfront.net/EWI/Over%20de%20faculteit/Afdelingen/Intelligent%20Systems/Pattern%20Recognition%20Laboratory/PR/Reading%20Group/Foundations_of_Machine_Learning.pdf)
- Narin, A., İşler, Y., & Özer, M. (2014). **Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı I Karşılaştırılması** (Comparison of the Effects of Cross Validation Methods on Determining Performances of Classifiers Used in Diagnosing Congestive Heart Failure), 1–8.
- Nawi, N. M., Khan, A., & Rehman, M. Z. (2013). **A New Levenberg Marquardt Based Back Propagation Algorithm Trained with Cuckoo Search.** *Procedia Technology*, 11(Iceei), 18–23. <https://doi.org/10.1016/j.protcy.2013.12.157>
- Nilsson, N. J. (1996). **Introduction to Machine Learning an Early Draft of a Proposed Textbook.**
- Öğündür, G. (2019). **Doğruluk (Accuracy) , Kesinlik(Precision) , Duyarlılık(Recall) ya da F1 Score ?** Retrieved July 29, 2021, from <https://medium.com/@gulcanogundur/doğruluk-accuracy-kesinlik-precision-duyarlılık-recall-ya-da-f1-score-300c925feb38>

- Okkan, U., Ali, S. Z., & Gedik, N. (2018). **Matlab ile Levenberg-Marquardt Algoritması Tabanlı YSA Uygulaması: Aylık Yağış-Akış Modellemesi.** *DÜMF Mühendislik Dergisi*, 9(1), 351–362. Retrieved from <http://dergipark.gov.tr/dumf/issue/36316/412696>
- Okur, Y. (2016). **Akdeniz Bölgesine Ait Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini.** Osmaniye Korkut Ata Üniversitesi.
- Önal, E., & Yarbay, R. Z. (2010). **Türkiye’de Yenilenebilir Enerji Kaynakları Potansiyeli ve Geleceği.** *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*.
- ORHAN, U., & ADEM, K. (2012). **Naive Bayes Yönteminde Olasılık Çarpanlarının Etkileri.** *Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu ELECO, Bursa*, 722–724.
- Özdamar, A. (2005). **Yenilenebilir Enerji Kaynakları: Gelgit Enerjisi.** *TMMOB Elektrik Mühendisleri Odası İzmir Şubesi Bülteni*. Retrieved from https://www.researchgate.net/publication/348369796_Yenilenebilir_Enerji_Kaynaklari_Gelgit_Enerjisi_Ozdamar
- Özen, İ. (2021). **Dünyada Güneş Enerjisi Üretimi ve Kullanımı.** Retrieved February 10, 2022, from <https://www.enerji.gen.tr/dunyada-gunes-enerjisi.html>
- Özmen, E. (2018). **Yenilenebilir Enerji Kaynaklarının Kullanımında Bir Model Olarak Güneş Şehirleri: Manisa Örneği.**
- Öztemel, E. (2008). **Yapay sinir ağları.** *papatyabilim.com.tr NNNN*. 1. Retrieved from http://papatyabilim.com.tr/PDF/yapay_sinir_aglari.pdf
- Reikard, G. (2009). **Predicting Solar Radiation At High Resolutions: A Comparison Of Time Series Forecasts.** *Solar Energy*, 83(3), 342–349. <https://doi.org/10.1016/j.solener.2008.08.007>
- Şahan, M., Tokat, Ö., & Okur, Y. (2015). **Osmaniye’de Günlük Toplam Güneş Işınım Ölçümleri Daily Global Solar Radiation Measurements in Osmaniye.** *SDU Journal of Science (E-Journal)*, 10(2), 97–105.
- Şahin, M. (2019). **Sivas İlinin Güneş Işınım Şiddeti ve Rüzgar Hızının Yapay Sinir Ağları İle Tahmin Edilmesi.** *Problem Set 2*. Cumhuriyet Üniversitesi.
- Saner, H. S. (2015). **Türkiye’de Güneş Enerjisi Santrallerinin Yer Seçimi ve Çevresel Etkileri: Karapınar ve Karaman Enerji İhtisas Endüstri Bölgeleri Örneklerinin Değerlendirilmesi.** Ankara Üniversitesi.
- Sarıgül, T. (2016). **TÜBİTAK.** Retrieved February 9, 2022, from

<https://bilimgenc.tubitak.gov.tr/makale/gunes-sisteminin-en-yakin-komsusunda-baska-bir-dunya-olabilir>

- Sarle, W. S. (1994). **Neural Networks and Statistical Learning**. *Neural Networks and Statistical Learning*, 9781447155, 1–824. <https://doi.org/10.1007/978-1-4471-5571-3>
- Sekin, S. (1999). Rüzga Enerjisi. *Öneri Dergisi*. <https://doi.org/10.14783/maruoneri.691197>
- Şengöz, N. (2017). **Derin Öğrenme**. Retrieved from <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>
- Sorkun, M. C. (2018). **Time Series Forecasting On Solar Radiation Using Deep Learning**. Director. Galatasaray University. Retrieved from [http://awsassets.wmfz.panda.org/downloads/earth_summit_2012_v3.pdf%0Ahttp://hdl.handle.net/10239/131%0Ahttps://www.uam.es/gruposinv/meva/publicaciones/jesus/capitulos_espanyol_jesus/2005_motivacion para el aprendizaje Perspectiva alumnos.pdf%0Ahttps://ww](http://awsassets.wmfz.panda.org/downloads/earth_summit_2012_v3.pdf%0Ahttp://hdl.handle.net/10239/131%0Ahttps://www.uam.es/gruposinv/meva/publicaciones/jesus/capitulos_espanyol_jesus/2005_motivacion_para_el_aprendizaje_Perspectiva_alumnos.pdf%0Ahttps://ww)
- Steward, K. (2019). **Sensitivity vs Specificity | Technology Networks**. Retrieved from <https://www.technologynetworks.com/analysis/articles/sensitivity-vs-specificity-318222>
- Tektas, M. (2010). **Weather forecasting using ANFIS and ARIMA models**. *Environmental Research, Engineering and Management*, 51(1), 5–10.
- Toka, B., & Şahin, M. (2006). **Havza Jeotermal Sahasında Yapılan Sh-5 Ve Diğer Sondajların Genel Değerlendirmesi**. *Bilimsel Madencilik Dergisi*, 45(1). Retrieved from <http://www.mining.org.tr/tr/pub/madencilik/issue/32500/361226>
- Topal, M., & Topal, E. I. A. (2008). **Bioyokütle Enerjisi ve Türkiye**, (May).
- Topaloğlu, V. (2007). *Yapay Sinir Ağları İle Dalga Yüksekliği Tahmini*. İstanbul Teknik Üniversitesi.
- Turaç, A. (2020). **Yapay Sinir Ağları İle Tahminleme: Türkiye'nin İhracatının Tahmini Üzerine Bir Uygulama**. Gebze Teknik Üniversitesi.
- Üçgül, İ., & Elibüyük, U. (2017). **Yenilenebilir Enerji Kaynakları ve Enerji Jeopolitiği**, 8.
- Uğuz, S., Oral, O., & Çağlayan, N. (2019). **PV Güç Santrallerinden Elde Edilecek Enerjinin Makine Öğrenmesi Metotları Kullanılarak Tahmin Edilmesi**. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 11(3), 769–779.

Retrieved from <http://dx.doi.org/10.29137/umagd.514933>

- URL1. (2021). **Türkiye’de Güneş Enerjisi Potansiyeli**. Retrieved August 22, 2021, from <https://www.incitas.com.tr/bilgi-merkezi/blog/turkiyede-gunes-enerjisi-potansiyeli>
- URL2. (2021). **Doğruluk, Hassasiyet, Hata (Accuracy, Precision, Error)**. Retrieved August 8, 2021, from <https://veribilimcisi.com/2017/07/14/dogrulukaccuracy-kesinlikprecision-hataerror-nedir/>
- URL3. (2018). **Psikoloji Öğrencisinden Notlar: Fizyolojik Psikoloji**. Retrieved February 10, 2022, from <http://psikolojisibozukolanlar.blogspot.com/2018/11/fizyolojik-psikoloji.html>
- URL4. (2021). **Güneş Enerjisi Tarihi**. Retrieved July 15, 2021, from <https://nexten.com.tr/tr/gunes-enerjisi-tarihi/>
- URL5. (2021). **MSE, RMSE, MAE, MAPE ve Diğer Metrikler**. Retrieved July 5, 2021, from <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>
- URL6. (2021). **Türkiye Elektrik İletim Anonim Şirketi**. Retrieved August 9, 2021, from <https://www.teias.gov.tr/>
- URL7. (2017). **Türkiye Enerji Haritası**. Retrieved from <https://ekolojist.net/turkiyede-gunes-enerjisi-kullanimi-potansiyel-degeri/>
- Ürün, E., & Soylu, E. (2016). **Türkiye’nin Enerji ÜretiminYenilenebilir Enerji Kaynakları Üzerine Bir Değerlendirme**. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 31–45.
- Uslu, Ç. S. (2011). **Zaman Serisi Analizi İle Yapay Sinir Ağları Kestirimlerinin Karşılaştırılması**. Mimar Sinan Güzel Sanatlar Üniversitesi. <https://doi.org/10.16194/j.cnki.31-1059/g4.2011.07.016>
- Yapar, M. (2020). **Yenilenebilir Enerji Kaynakları Kullanımı- İktisat Büyüme İlişkisi** : İstanbul Üniversitesi.
- Yarkan, E. H. (2006). **Güneş Enerjisi Kullanımında Sodyum Sıvılı Güneş Panellerinin İncelenmesi**. Pamukkale Üniversitesi.
- Yıldırım, H. H. (2016). **Türkiye’de Enerji Sorunu, Alternatif Çözüm Önerileri İçin Rüzgar Enerjisi ve Yatırımları: Güney Marmara Bölgesinde Rüzgar Enerjisi Yatırımlarının Risk ve Getiri Değerlendirmesi Üzerine Bir Uygulama**. *NASPA Journal*. İstanbul Üniversitesi. <https://doi.org/10.1017/CBO9781107415324.004>
- Yıldız, E. (2017). **Türkiye’de Yenilenebilir Enerji Kaynakları, Uygulama: Güneş Enerji**

Santrali ve Rüzgar Enerji Santrali Kuruluş Maliyetleri. Trakya Üniversitesi Sosyal Bilimler.

Yılmaz, M. (2012). **Türkiye'nin Enerji Potansiyeli ve Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Açısından Önemi.** *Ankara Üniversitesi Çevre Bilimleri Dergisi*, 4(2), 33–54. https://doi.org/10.1501/csau_00000000064

Yolcan, O. O., & Köse, R. (2020). **Türkiye'nin Güneş Enerjisi Durumu ve Güneş Enerjisi Santrali Kurulumunda Önemli Parametreler.** *Kırklareli Üniversitesi Mühendislik ve Fen Bilimleri Dergisi*, 2, 196–215. <https://doi.org/10.34186/klujes.793471>

