



**GÜNEŞ IŞINIM TAHMİNİ İÇİN ZAMAN SERİSİ
TEMELLİ YENİ HİBRİT BİR YAKLAŞIM**

DOKTORA TEZİ

Burak ARSEVEN

Danışman

Doç. Dr. Said Mahmut ÇINAR

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

Temmuz 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

**GÜNEŞ IŞINIM TAHMİNİ İÇİN ZAMAN SERİSİ
TEMELLİ YENİ HİBRİT BİR YAKLAŞIM**

Burak ARSEVEN

Danışman

Doç. Dr. Said Mahmut ÇINAR

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

Temmuz 2025

TEZ ONAY SAYFASI

Burak ARSEVEN tarafından hazırlanan “**Güneş Işınım Tahmini için Zaman Serisi Temelli Yeni Hibrit Bir Yaklaşım**” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca **01/07/2025** tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Said Mahmut ÇINAR

Başkan : Prof. Dr. Hasan Çimen
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi

Üye : Prof. Dr. Ali Bekir YILDIZ
Kocaeli Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Said Mahmut ÇINAR
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Emre AKARSLAN
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Dr. Öğr. Üyesi Mustafa NİL
Manisa Celal Bayar Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

01 / 07 / 2025

Burak ARSEVEN

ÖZET

Doktora Tezi

GÜNEŞ IŞINIM TAHMİNİ İÇİN ZAMAN SERİSİ TEMELLİ YENİ HİBRİT BİR YAKLAŞIM

Burak ARSEVEN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Said Mahmut ÇINAR

Güneş ışıınımı tahmini konusu, güneş enerjisi sistemlerinin verimliliğini artırmak, enerji üretimini optimize etmek ve şebeke yönetimini geliştirmek açısından kritik öneme sahiptir. Özellikle kısa vadeli tahminler, bulutluluk değişimleri gibi atmosferik dalgalanmaların enerji üretimi üzerindeki etkilerine hızlı bir şekilde uyum sağlanmasını mümkün kılarak, enerji arz ve talep dengesinin korunmasına katkıda bulunmaktadır. Literatürde, güneş ışıınımı tahmini konusunda farklı veri setleri ve teknikler kullanılarak birçok çalışma gerçekleştirilmiştir.

Tez kapsamında ilk olarak, Afyon Bölge İstasyonu'nda (ABİ) toplanan ve her biri saatlik formatta olan ışıınım, ortalama hava sıcaklığı ve bağıl nem verilerinin farklı kombinasyonları kullanılarak çok değişkenli ridge regresyon (MRR) ve çok değişkenli lasso regresyon (MLR) yöntemleri kullanılarak tahminleme işlemi gerçekleştirilmiştir (BRBA yaklaşımı). İkincil olarak, veri setleri tek boyutlu ayrık dalgacık dönüşümü (DWT) tekniği ile farklı seviyelerde ayrıştırılmış ve ayrıştırma sonucunda elde edilen alt sinyaller için ayrı ayrı MRR ve MLR modelleri geliştirilerek tahminleme işlemi gerçekleştirilmiştir (WRBA yaklaşımı). Son olarak, farklı giriş veri seti kombinasyonları için oluşturulan DWT-MRR ve DWT-MLR modelleri ile yapılan tahminlerin etkinlikleri, kernel k-means algoritması kullanılarak sınırları belirlenen açıklık endeksi (CI) kümelerinde incelenmiş, sonrasında her bir kümede farklı modellerle gerçekleştirilen tahminlerin en iyi sonuçları verdiği tespit edilmiştir. Son olarak her kümede en iyi tahmin

sonularını veren modeller kullanılarak hibrit bir tahmin modeli oluřturulmuř ve en doėru sonular bu hibrit modelle elde edilmiřtir (CA-WRBA yaklařımı).

Önerilen yaklařımlardan CA-WRBA ile yapılan tahminlerin sonularına bakıldıėında, ok bulutlu (MC) kümede ıřınım ve baėıl nem verilerinin kullanıldıėı DWT-MLR-V1 modeli, bulutlu (C) kümede ıřınım, baėıl nem ve ortalama hava sıcaklıėı verilerinin kullanıldıėı DWT-MRR-V3 modeli ve az bulutlu (SC) kümede ise ıřınım ve ortalama hava sıcaklıėı verilerinin kullanıldıėı DWT-MLR-V2 modeli en bařarılı sonuları verdiėi belirlenmiřtir. Sonu olarak, her kümede en iyi sonucu veren modellerin hibritlenmesi ile altı aylık ve bir yıllık test dönemleri iin olduėa bařarılı tahmin sonuları elde edilmiřtir.

2025, xiii + 106 sayfa

Anahtar Kelimeler: ıřınım tahmini, Makine öėrenmesi, ok deėiřkenli ridge regresyon, ok deėiřkenli lasso regresyon, Ayrık dalgacık dönüşümü, Açıklık endeksi, Kernel k-means algoritması.

ABSTRACT

Ph.D. Thesis

A TIME SERIES BASED NEW HYBRID APPROACH FOR SOLAR RADIATION FORECASTING

Burak ARSEVEN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Electrical-Electronics Engineering

Supervisor: Doç. Dr. Said Mahmut ÇINAR

Short-term solar radiation forecasting is critically important for improving the efficiency of solar energy systems, optimizing energy production, and enhancing grid management. In particular, short-term forecasts enable rapid adaptation to atmospheric fluctuations such as cloud cover variations, thereby contributing to the balance between energy supply and demand. In the literature, numerous solar radiation forecast studies have been conducted using different datasets and techniques.

Within the scope of this thesis, initial forecasts were performed using multivariate ridge regression (MRR) and multivariate lasso regression (MLR) models based on different combinations of hourly data collected at the Afyon Regional Station (ABİ), including radiation, average air temperature, and relative humidity (BRBA approach). In the second phase, the datasets were decomposed using various levels of one-dimensional discrete wavelet transform (DWT). Separate MRR and MLR models were then developed for each resulting sub-signal to perform forecasting (WRBA approach). Finally, the performance of the DWT-MRR and DWT-MLR models—constructed for various input dataset combinations—was evaluated across clusters defined by the clearness index (CI) using the kernel k-means algorithm. Within each cluster, the models yielding the most accurate forecasts were identified. A hybrid forecasting model was then developed by integrating the best-performing models in each cluster, resulting in the most accurate predictions overall (CA-WRBA approach).

According to the proposed CA-WRBA approach results, the DWT-MLR-V1 model utilizing radiation and relative humidity data provided the best forecasts in the mostly cloudy (MC) cluster. In the cloudy (C) cluster, the DWT-MRR-V3 model, which used radiation, relative humidity, and average air temperature, yielded the most accurate results. For the slightly cloudy (SC) cluster, the DWT-MLR-V2 model was the most successful based on radiation and average air temperature. By hybridizing the best-performing models from each cluster, highly accurate forecasts were achieved for both six-month and one-year testing periods.

2025, xiii + 106 pages

Keywords: Radiation forecast, Machine learning, Multivariate ridge regression, Multivariate lasso regression, Discrete wavelet transform, Clearness index, Kernel k-means algorithm.

TEŞEKKÜR

Öncelikle, yalnızca yüksek lisans ve doktora tez süreçlerimde değil, aynı zamanda düşünsel gelişimime de büyük katkılar sağlayan, akademik hayatım boyunca bana hep yol gösteren ve bir akademisyen olmanın ötesinde bir abi olarak gördüğüm danışmanım Doç. Dr. Said Mahmut ÇINAR'a en derin şükranlarımı sunarım. Kendisi, bilgi ve tecrübeleriyle bana daima rehberlik etmiş ve bu tezin ortaya çıkmasında en büyük katkıyı sağlamıştır.

Tezim boyunca gerçekleştirdiğim Tez İzleme Komiteleri'nde yer alarak yapıcı eleştirileri ve kıymetli yönlendirmeleriyle bu sürece önemli katkılar sunan Prof. Dr. Ali Bekir YILDIZ ve Doç. Dr. Emre AKARSLAN'a teşekkür ederim.

Bu tez kapsamında kullanılan verileri sağlayarak çalışmamıza önemli destek veren Meteoroloji 5. Bölge Müdürlüğü'ne de ayrıca teşekkürlerimi sunarım.

Bugüne kadar her adımında yanımda olan, durum ve şartlar ne olursa olsun beni destekleyen ve fedakarlıklarıyla bugünlere gelmemde en büyük katkıyı sağlayan babam Mehmet ARSEVEN ve annem Şengül ARSEVEN'e sonsuz teşekkür ederim.

Bir diğer teşekkürüm ise hayatıma anlam, mutluluk ve huzur katan sevgili eşim Av. Arb. Uzl. Nur BOZOK ARSEVEN ve en büyük motivasyon kaynağım olan kıymetli oğlum ve en yakın arkadaşım Baturalp ARSEVEN'e sonsuz teşekkür ederim. Varlıklarıyla bana güç verdikleri ve bu süreci büyük bir hoşgörü ve anlayışla destekledikleri için minnettarım.

Son olarak, başta sevgili kardeşim Buse ARSEVEN HASTÜRK olmak üzere, adını burada tek tek sayamadığım eşimin ailesine, kardeşimin eşine, kıymetli mesai arkadaşlarıma ve tezimin tamamlanmasında emeği geçen herkese şükranlarımı sunarım.

Burak ARSEVEN
Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	5
3. MATERYAL ve METOT	19
3.1 Açıklık Endeksi (Clearness Index-CI)	19
3.2 Kullanılan Makine Öğrenmesi Tabanlı Yöntemler	21
3.2.1 Çok Değişkenli Ridge Regresyon Yöntemi	21
3.2.2 Çok Değişkenli Lasso Regresyon Yöntemi	23
3.3 Dalgacık Dönüşümü	24
3.3.1 Sürekli Dalgacık Dönüşümü	26
3.3.2 Ayırık Dalgacık Dönüşümü	27
3.4 Kümeleme Algoritmaları	29
3.4.1 Manuel Yöntem.....	30
3.4.2 K-Means Algoritması	31
3.4.3 Kernel K-Means Algoritması	32
3.5 Performans Analizi	35
3.5.1 İstatistiksel Performans Ölçütleri	35
3.5.2 Grafikselleştirme Yöntemleri.....	39
4. ÖNERİLEN İŞİNİM TAHMİN YAKLAŞIMLARI	41
4.1 Temel Regresyon Tabanlı Yaklaşım.....	41
4.2 Dalgacık ve Regresyon Tabanlı Yaklaşım.....	43
4.3 Kümeleme Destekli Dalgacık ve Regresyon Tabanlı Yaklaşım.....	45
5. BULGULAR	47
5.1 Kullanılan Veri Setleri	47

5.2 Tüm Veri Setlerinin ve Açıklık Endeksi Değerlerinin Ayrıştırılması	56
5.3 Çok Değişkenli Ridge ve Lasso Regresyon Modellerinin Belirlenmesi	61
5.4 Kümeleme Süreçleri	64
5.5 Nihai Tahmin Sonuçları.....	71
5.5.1 Temel Regresyon Tabanlı Yaklaşım ile Elde Edilen Tahmin Sonuçları.....	71
5.5.2 Dalgacık ve Regresyon Tabanlı Yaklaşım ile Elde Edilen Tahmin Sonuçları.	75
5.5.3 Kümeleme Destekli Dalgacık ve Regresyon Tabanlı Yaklaşım ile Elde Edilen Tahmin Sonuçları	84
6. SONUÇLAR.....	92
7. KAYNAKLAR.....	96
ÖZGEÇMİŞ.....	104

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

°C	Santigrat derece
G	Saatlik ışıınım değeri
H	Saatlik bağıl nem değeri
kWh/m ²	Kilowatt saat bölü metrekare
T	Saatlik ortalama hava sıcaklığı değeri
W/m ²	Watt bölü metrekare

Kısaltmalar

ABİ	Afyon Bölge İstasyonu
ACO	Karınca kolonisi optimizasyonu
AI	Yapay zeka
AIC	Akaike bilgi kriteri
ANFIS	Uyarlanabilir nöro bulanık çıkarım sistemi
ANN	Yapay sinir ağı
A-P	Angstörm-Prescott
ARIMA	Oto regresif entegreli hareketli ortalama
ARMA	Oto regresif hareketli ortalama
BDTR	Artırılmış karar ağacı regresyonu
BPNN	Geri yayımlı sinir ağı
BRBA	Temel regresyon tabanlı yaklaşım
BRR	Bayesian ridge regresyonu
CA-WRBA	Kümeleme destekli dalgacık ve regresyon tabanlı yaklaşım
CI	Açıklık endeksi
CNN	Evrişimsel sinir ağı
CWT	Sürekli dalgacık dönüşümü
db	Daubechies
DBSCAN	Yoğunluk tabanlı kümeleme
DHI	Difüz yatay ışıınım
DL	Derin öğrenme
DNI	Doğrudan normal ışıınım
DNN	Derin sinir ağı
DTR	Karar ağacı regresyonu
DWT	Ayrık dalgacık dönüşümü
DWT-MLR	Ayrık dalgacık dönüşümü çok değişkenli lasso regresyon
DWT-MRR	Ayrık dalgacık dönüşümü çok değişkenli ridge regresyon
EMD	Ampirik mod ayrıştırma
ER	Dünya dışı ışıınım
GEPA	Güneş Enerjisi Potansiyeli Atlası
GHI	Toplam yatay ışıınım
GSI	Küresel güneş ışıınımı
GRU	Kapılı tekrarlayan birim
HPF	Yüksek geçiren filtre
JB	Jarque-Bera
LPF	Alçak geçiren filtre

LR	Lasso regresyon
LSTM	Uzun kısa dönem bellek
ML	Makine öğrenmesi
MLP	Çok katmanlı algılayıcı
MLPNN	Çok katmanlı algılayıcı sinir ağı
MLR	Çok değişkenli lasso regresyon
MRR	Çok değişkenli ridge regresyon
MVRB	Çok değişkenli regresyon tabanlı
NMAE	Normalize edilmiş ortalama mutlak hata
NN	Sinir ağı
NRMSE	Normalize edilmiş kök ortalama karesel hata
OR	Doğrusal/sıradan regresyon
PV	Fotovoltaik
RB	Regresyon tabanlı
REGST	Çift aşamalı yayılmış regresyon
RF	Rastgele orman
RFR	Rastgele orman regresyonu
RMSE	Kök ortalama karesel hata
RR	Ridge regresyonu
RTM	Radyatif transfer modeli
SS	Silhouette skoru
SVR	Destek vektör regresyonu
SVM	Destek vektör makinesi
ULR	Tek değişkenli lasso regresyon
URR	Tek değişkenli ridge regresyon
V1	Versiyon-1
V2	Versiyon-2
V3	Versiyon-3
VMD	Varyasyonel mod ayrıştırma
WRBA	Dalgacık ve regresyon tabanlı yaklaşım
WT	Dalgacık dönüşümü

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Türkiye'nin güneş enerjisi potansiyeli atlası (GEPA).....	7
Şekil 2.2 Güneş ışınlımı tahmin çalışmalarının genel kategorilere göre sınıflandırılması.8	
Şekil 2.3 Güneş ışınlımı tahmininde kullanılan başlıca yöntemlerin sınıflandırılması.....	9
Şekil 3.1 DWT ayrıştırma ağacı.	28
Şekil 4.1 Temel regresyon tabanlı yaklaşım (Basic Regression Based Approach-BRBA) için oluşturulmuş prensip şeması.	42
Şekil 4.2 Dalgacık ve regresyon tabanlı yaklaşım (Wavelet and Regression Based Approach-WRBA) için oluşturulmuş prensip şeması.	44
Şekil 4.3 Kümeleme destekli dalgacık ve regresyon tabanlı yaklaşım (Cluster Assisted Wavelet and Regression Based Approach, CA-WRBA) için oluşturulmuş prensip şeması.	46
Şekil 5.1 Çalışma alanına ait yer bulduru haritası.....	49
Şekil 5.2 Saatlik güneş ışınlımı verileri.....	50
Şekil 5.3 Saatlik ortalama hava sıcaklığı verileri.	50
Şekil 5.4 Saatlik bağıl nem verileri.	51
Şekil 5.5 ABİ konumuna ait bir yıllık ER değerleri.	54
Şekil 5.6 Saatlik CI değerleri.	55
Şekil 5.7 Birinci seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.	58
Şekil 5.8 Birinci seviye ayrıştırma sonucu elde edilen detay sinyalleri.....	58
Şekil 5.9 İkinci seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.	59
Şekil 5.10 İkinci seviye ayrıştırma sonucu elde edilen detay sinyalleri.....	59
Şekil 5.11 Üçüncü seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.	60
Şekil 5.12 Üçüncü seviye ayrıştırma sonucu elde edilen detay sinyalleri.....	60
Şekil 5.13 Dördüncü seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.	61
Şekil 5.14 Dördüncü seviye ayrıştırma sonucu elde edilen detay sinyalleri.	61
Şekli 5.15 Manuel yöntem ile elde edilen SS değerleri.	70
Şekil 5.16 K-means algoritması ile elde edilen SS değerleri.	70
Şekil 5.17 Kernel k-means algoritması ile elde edilen SS değerleri.	71
Şekil 5.18 MRR-V1 ile elde edilen altı aylık tahminlerin karşılaştırması.	74
Şekil 5.19 MRR-V1 ile elde edilen bir yıllık tahminlerin karşılaştırması.	74
Şekil 5.20 Ayrıştırma seviyeleri için modellerin AIC değerleri (yaklaşık sinyalleri için).	78
Şekil 5.21 Ayrıştırma seviyeleri için modellerin AIC değerleri (detay sinyalleri için)..	78

Şekil 5.22 DWT-MLR-V2 ile elde edilen altı aylık tahminlerin karşılaştırması.	83
Şekil 5.23 DWT-MLR-V2 ile elde edilen bir yıllık tahminlerin karşılaştırması.....	84
Şekil 5.24 Tüm tahmin modellerinin CI kümelerindeki performansları (üç buçuk yıllık eğitim dönemi için).	86
Şekil 5.25 Tüm tahmin modellerinin CI kümelerindeki performansları (üç yıllık eğitim dönemi için).....	87
Şekil 5.26 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (radar grafikleri-altı aylık test dönemi için).....	88
Şekil 5.27 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (radar grafikleri-bir yıllık test dönemi için).....	89
Şekil 5.28 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (Taylor diyagramı-altı aylık test dönemi için).	89
Şekil 5.29 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (Taylor diyagramı-bir yıllık test dönemi için).	90
Şekil 5.30 CA-WRBA kapsamında önerilen model ile elde edilen altı aylık tahminlerin karşılaştırması.....	91
Şekil 5.31 CA-WRBA kapsamında önerilen model ile elde edilen bir yıllık tahminlerin karşılaştırması.....	91

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Kullanılan kümeleme algoritmalarının karşılaştırması.	34
Çizelge 3.2. Kullanılan istatistiksel performans ölçütlerinin karşılaştırması.	38
Çizelge 5.1 Işınım, sıcaklık ve bağıl nem değişkenlerinin istatistiksel göstergeleri.	51
Çizelge 5.2 Dünya dışı ışıınım (ER) parametresine ilişkin istatistiksel göstergeler.	54
Çizelge 5.3 Açıklık endeksi (CI) parametresine ilişkin istatistiksel göstergeler (sadece güneşli saatler için).	55
Çizelge 5.4 BRBA için tüm versiyonların model katsayıları (üç buçuk yıllık eğitim dönemi için).	62
Çizelge 5.5 BRBA için tüm versiyonların model katsayıları (üç yıllık eğitim dönemi için).	63
Çizelge 5.6 WRBA ve CA-WRBA için DWT-MRR modelleri katsayıları (üç buçuk yıllık eğitim dönemi için).	64
Çizelge 5.7 WRBA ve CA-WRBA için DWT-MLR modelleri katsayıları (üç buçuk yıllık eğitim dönemi için).	65
Çizelge 5.8 WRBA ve CA-WRBA için DWT-MRR modelleri katsayıları (üç yıllık eğitim dönemi için).	66
Çizelge 5.9 WRBA ve CA-WRBA için DWT-MLR modelleri katsayıları (üç buçuk yıllık eğitim dönemi için).	67
Çizelge 5.10 Oluşturulan CI kümelerinin sınırları (üç buçuk yıllık eğitim dönemi için).	68
Çizelge 5.11 Oluşturulan CI kümelerinin sınırları (üç yıllık eğitim dönemi için).	69
Çizelge 5.12 BRBA ile oluşturulan modellerin AIC değerleri (üç buçuk yıllık eğitim dönemi için).	72
Çizelge 5.13 BRBA ile oluşturulan modellerin AIC değerleri (üç yıllık eğitim dönemi için).	72
Çizelge 5.14 BRBA kapsamında oluşturulan tüm modellerin performansları.	73
Çizelge 5.15 WRBA ile oluşturulan modellerin AIC değerleri (üç buçuk yıllık eğitim dönemi için).	76
Çizelge 5.16 WRBA ile oluşturulan modellerin AIC değerleri (üç yıllık eğitim dönemi için).	77
Çizelge 5.17 DWT-MRR modellerinin β değerleri (üç buçuk yıllık eğitim dönemi için).	79
Çizelge 5.18 DWT-MLR modellerinin β değerleri (üç buçuk yıllık eğitim dönemi için).	80
Çizelge 5.19 DWT-MRR modellerinin β değerleri (üç yıllık eğitim dönemi için).	81

Çizelge 5.20 DWT-MLR modellerinin β değerleri (üç buçuk yıllık eğitim dönemi için).	81
Çizelge 5.21 WRBA kapsamında oluşturulan tüm modellerin performansları.....	82
Çizelge 5.22 Tüm modellerin oluşturulan CI kümelerindeki performansları (üç buçuk yıllık eğitim dönemi için).	85
Çizelge 5.23 Tüm modellerin oluşturulan CI kümelerindeki performansları (üç yıllık eğitim dönemi için).	86



1. GİRİŞ

En genel tanımıyla enerji, fiziksel iş yapabilme kapasitesidir. Doğada çeşitli biçimlerde bulunabilen ve birbirleri arasında dönüşüme uğrayabilen enerji, ısı, ışık, hareket ve kimyasal reaksiyonlar gibi farklı formlara sahiptir (Garver 1916). İnsanlık tarihinin her aşamasında enerji ihtiyacının karşılanması konusu hayati bir öneme sahip olmuştur. Günümüzün modern toplumlarında enerji; sanayi, ulaşım, sağlık, tarım ve teknoloji gibi temel alanların etkinliği ve sürdürülebilirliği açısından hayatın vazgeçilmezleri arasında kabul edilmektedir (Christophorou 2014). Siyasal açıdan ise enerji kaynaklarına sahip ülkeler, küresel politikada önemli bir güç unsuru haline gelirken, enerjiye bağımlı ülkeler dış politikalarını bu bağımlılığa göre şekillendirmek zorunda kalmaktadır.

Kaynaksal açıdan enerji, yenilenebilir ve yenilenemeyen enerji kaynakları olarak iki ana kategoriye ayrılmaktadır. Petrol, doğalgaz ve kömür gibi fosil kaynaklar, özellikle sanayi devriminden bu yana dünya enerji talebinin büyük bir kısmını karşılamaktadır. Ancak bu kaynaklar, olumsuz çevresel etkileri ve sınırlı rezervleri nedeniyle uzun vadede sürdürülebilir bir perspektif sunmazlar (Urry 2014). Uranyum ve toryum gibi nükleer enerji kaynaklarının kullanılmasıyla da elektrik üretimi sağlanmaktadır. Her ne kadar nükleer enerji kaynakları yapılarında karbon elementini içermiyor olsalar bile, bu kaynakların atık yönetimi ve güvenlik riskleri büyük tartışmalara yol açmakta ve mümkün olduğunca bu kaynaklara başvurulmaması otoriteler tarafından vurgulanmaktadır. Güneş, rüzgar, hidroelektrik, jeotermal, biyogaz ve biyokütle gibi çeşitleri bulunan yenilenebilir enerji kaynakları ise, sürdürülebilir olmaları ve çevre dostu yapıları sayesinde fosil ve nükleer kaynakların sebep olabileceği olumsuz etkileri minimize etme potansiyeline sahiptir. Ayrıca, yenilenebilir enerji kaynakları enerji arzı noktasında güvenliği artırarak fosil yakıtlara olan bağımlılığı azaltmakta ve karbon emisyonlarının düşürülmesine katkı sağlamaktadır. Özellikle küresel iklim değişikliği ile mücadelede, enerji dönüşüm süreçlerinde yenilenebilir kaynakların rolü giderek daha fazla önem kazanmaktadır. Bu temiz enerji kaynakları, doğal süreçlerden elde edildikleri için tükenme riskleri de oldukça düşüktür.

Yenilenebilir ve sürdürülebilir enerji kaynakları arasında potansiyeli en yüksek olan hiç kuşkusuz güneş enerjisidir. Yaşamın devamlılığının ana kaynağı olan güneş enerjisinden, fotovoltaiik (PV) paneller ve güneş termal sistemleri yardımıyla elektrik enerjisi üretilebilir. Güneş termal sistemleri prensip olarak güneş ışığını toplayarak suyu ısıtan veya elektrik üretimi için termal enerjiye dönüştüren sistemlerdir. Fakat güneş enerjisinden elektrik enerjisi üretme noktasında PV paneller daha yaygın bir şekilde kullanılmaktadır. PV panelleri, yapılarında yer alan yarı iletken malzemeler sayesinde üzerlerine gelen güneş ışığı miktarına bağlı olarak elektrik enerjisi üretmektedirler. PV paneller, güneş ışıınımını doğrudan elektrik enerjisine çevirebilen yarı iletken cihazlardır (Çınar ve Arseven 2021). Bu dönüşüm, fotoelektrik etki olarak adlandırılan üç aşamalı fiziksel bir süreç sayesinde gerçekleşmektedir. İlk aşamada, PV üzerine gelen güneş ışığı fotonları, PV hücresinin yüzeyine çarptığında, yarı iletken malzeme içindeki elektronlar uyarılarak daha yüksek enerji seviyesine taşınırlar. İkinci aşamada, PV hücresinde bulunan eklem bağlantısı, bu elektronların belirli bir yönde hareket etmesini sağlayan bir elektrik alanı oluşturur. Üçüncü aşamada ise elektronların hareket etmesiyle devrede elektrik akımı oluşmuş ve dolayısıyla elektrik enerjisi üretilmiş olur (Hersch ve Zweibel 1982).

PV panellerin verimliliğini etkileyen birçok faktör bulunmaktadır. Bu faktörlerden olan ışıınım miktarı ve spektral dağılım ise en önemli etkenlerdendir. Ayrıca, çevresel sıcaklık arttıkça PV yapısındaki yarı iletkenlerin bant aralığı değişebilir ve bu yüzden elektrik üretimi azalabilir. Bunun yanı sıra, panelin yönü, eğim açısı, gölgelenme ve panel yüzeyinin kirlenmesi gibi fiziksel faktörler de PV sistemlerinin performansını etkilemektedir. Güneş ışıınımı, PV panellerin verimini etkileyen en temel değişkendir. Güneş ışıınımı, doğrudan normal ışıınım (Direct Normal Irradiance-DNI), difüz yatay ışıınım (Diffuse Horizontal Irradiance-DHI) ve yansıyan olmak üzere üç ana bileşene ayrılmaktadır. Toplam yatay ışıınım (Global Horizontal Irradiance-GHI) ise bu üç bileşenin toplamıdır. DNI, atmosfer tarafından dağılmadan PV yüzeyine ulaşan ışıındır ve aynı zamanda PV sistemlerinin üreteceği elektriği en çok etkileyenidir. DHI, atmosferde saçıldıktan sonra yeryüzüne ulaşan ışıındır. GHI ise DHI ve güneşin zenit açısıyla çarpılmış DNI'nın toplamına eşittir (Stein vd. 2012).

PV panellerinden üretilecek elektrik enerjisinin belirlenmesi noktasında ise güneş ışınımının etkin bir şekilde tahmin edilmesi konusu önemli bir rol oynamaktadır. PV sistemlerinin verimli çalışmasını sağlamak, enerji arz ve talep dengesini optimize etmek ve şebeke entegrasyonunu güçlendirmek için doğru ışınım tahminlerine ihtiyaç duyulmaktadır. Saatlik, günlük, haftalık ve mevsimsel tahminler, güneş enerjisi sistemlerinin etkin yönetimi açısından oldukça önemlidir. Saatlik tahminler, özellikle anlık enerji talebi yönetimi ve şebeke dengelemesi için büyük önem taşımaktadır. Bu tahminler, kısa vadeli enerji üretim dalgalanmalarının öngörülmesine yardımcı olmasıyla fotovoltaik (PhotoVoltaic-PV) sistemlerinin ve enerji depolama birimlerinin daha verimli kullanılmasında önemli bir öngörü sağlamaktadır. Işınımın yanı sıra bulut örtüsü, nem oranı ve atmosferik değişkenlik gibi faktörler, saatlik tahminlerin doğruluğunu etkileyen diğer temel unsurlardır. Günlük bazda gerçekleştirilen tahminler, enerji sağlayıcıları ve şebeke operatörleri tarafından talep yönetimi ve enerji ticareti stratejilerinin belirlenmesi için kullanılmaktadır. Özellikle yenilenebilir enerji payı yüksek olan bölgelerde, bu tahminler elektrik fiyatlarının dalgalanmasını azaltmak ve enerji arz güvenliğini sağlamak açısından kritiktir (Debroy vd.). Haftalık tahminler, orta vadeli enerji üretim planlamasında yol göstericidir. Özellikle büyük ölçekli PV santrallerinde ve enerji depolama stratejilerinde haftalık öngörüler oldukça değerlidir. Mevsimsel tahminler ise uzun vadeli enerji politikalarının belirlenmesi, yatırım kararlarının alınması ve güneş enerjisi üretiminin yıllık değişimlerinin analiz edilmesi açısından önemlidir.

Güneş ışınımı tahminlerinin doğruluğunu artırmak için yapay zeka (Artificial Intelligence-AI), makine öğrenmesi (Machine Learning-ML), derin öğrenme (Deep Learning-DL) ve istatistiksel modelleme teknikleri yaygın bir şekilde kullanılmaktadır. Gelişmiş tahmin sistemleri, meteorolojik verilerle entegre edilerek daha hassas öngörüler sunmakta ve böylece PV sistemlerinin daha verimli kullanılmasına olanak tanımaktadır. Bu bağlamda, yüksek doğrulukta güneş ışınımı tahmini yapmak, PV sistemlerinin verimli çalışmasını sağlayarak, enerji arz ve talep dengesini optimize etmekte ve şebeke entegrasyonunu da artırmaktadır. Bu doktora tezinde güneş ışınımı tahminlerinin doğruluğunu artırmaya yönelik yeni yaklaşımlar sunulmaktadır. Özellikle saatlik tahminlerin hassasiyetini geliştirmek, mevcut PV sistemlerinin performansını optimize

etmenin yanı sıra, enerji arz ve talep dengesini anlık olarak yönetebilmek ve tahmin alanında gelecekteki çalışmalar için sağlam bir temel oluşturmak hedeflenmektedir.



2. LİTERATÜR BİLGİLERİ

İnsanlar yüzyıllardır güneş enerjisinden çok çeşitli amaçlarla faydalanmaktadır. Yaşam döngüsünün de temel kaynağı olan güneş enerjisi bilinen tarihte ilk olarak antik uygarlıklar tarafından pasif ısıtma kaynağı olarak kullanılmıştır. M.Ö. yedinci yüzyıla kadar camın da yardımıyla ateş yakmak amacıyla kullanılan güneş enerjisi, M.S. birinci yüzyılda Romalılar tarafından hamamların ve binaların ısıtılması için kullanılmıştır. Antik Yunan ve Çin uygarlıkları ise güneş ışığını aynalar yardımıyla yoğunlaştırarak farklı birçok yararlı model geliştirmiştir.

Modern anlamda güneş enerjisi teknolojilerinin temelleri 18. yüzyılda atılmaya başlanmıştır. 1767 yılında İsviçreli bilim insanı Horace-Bénédict de Saussure, ilk güneş kolektörünü icat etmiştir (Enebe vd. 2024). Bu cihaz, farklı katmanlardan oluşan cam paneller yardımıyla güneş ışığını emerek sıcaklığı artırmıştır. Bu buluş, modern güneş enerjisi teknolojilerine ilham kaynağı olmuş ve özellikle güneş fırınlarının ve sera teknolojisinin gelişiminde önemli bir rol oynamıştır. 1839 yılında Fransız fizikçi Alexandre Edmond Becquerel, platin, altın ve pirinç gibi belirli materyallerin ışığa maruz kaldığında elektrik üretebildiğini keşfetmiştir. Bu keşif, günümüzde kullanılan PV hücrelerinin de temellerini oluşturmuştur (Copeland vd. 1942). 20. yüzyılın ortalarında Swensson, Becquerel'in keşfini ileri taşıyarak yarı iletken malzemelerde ışığa duyarlılığın nasıl optimize edilebileceğini araştırmıştır. Swensson-Becquerel etkisi sayesinde, PV malzemelerin ışık emme kapasitesinin belirli dalga boylarında artırılacağı ve bu sayede güneş hücrelerinin verimliliğinin geliştirilebileceği öne sürülmüştür. Swensson yaptığı çalışmanın bulgularında bakır sülfat, nikel sülfat, çinko sülfat ve sülfürik asit gibi elektrolitlerin gerçekten de ışığa duyarlı olduğunu ve hücre tarafından üretilen potansiyeli değiştirdiğini bildirmiştir. Ayrıca, elektrolit konsantrasyonunun da oldukça önemli olduğunu çalışmasında bildirmiştir (Copeland vd. 1942, Malik vd. 2010).


PV etkinin keşfi ile birlikte, güneş enerjisinden elektrik üretimi yapılabileceği fikri ortaya atılmış, ancak bu alandaki çalışmalar özellikle 20. yüzyılın ikinci yarısında hız kazanmıştır. Bu sürecin ivmelenmesinde, 1973 yılında gerçekleşen petrol krizinin

yarattığı enerji güvenliği endişeleri önemli bir rol oynamış ve ülkeleri alternatif enerji kaynaklarına yönelmeye teşvik etmiştir (Aydın 2024). Petrol krizinin ardından, başta Amerika Birleşik Devletleri (ABD) ve Avrupa ülkeleri olmak üzere birçok ülke enerji bağımsızlığını artırma amacıyla yenilenebilir ve sürdürülebilir enerji teknolojilerine yönelik yatırımlar yapmaya ve bu yatırımları desteklemeye başlamıştır. 1980'ler ve 1990'larda, PV panellerinin verimliliğini artırmaya yönelik olarak yeni malzemeler ve üretim teknikleri geliştirilmiş, bu bağlamda çok kristalli (polikristalin) silikon güneş panelleri piyasaya sürülmüştür. Bu gelişmeler, üretim maliyetlerinin önemli ölçüde düşmesini sağlayarak daha geniş çaplı uygulamaların önünü açmıştır (Çepik 2015).

Güneş enerjisi, günümüzde dünya genelinde en hızlı büyüyen yenilenebilir enerji kaynaklarından biri olup, enerji arz-talep güvenliği ve çevresel sürdürülebilirlik açısından oldukça önemli bir rol oynamaktadır (Kaplukan 2014). Son yıllarda küresel enerji dönüşümünün temel bileşenlerinden biri haline gelen güneş enerjisinin elektrik üretimindeki payı birçok ülkede giderek artmaktadır. Gelişmiş ve gelişmekte olan ülkeler arasında, güneş enerjisinden elektrik üretme potansiyeli yüksek olan ülkelerde güneş enerjisi yatırımları hız kazanmış ve güneş enerjisinin toplam elektrik üretimindeki payı önemli ölçüde artmıştır. Yüksek güneş enerjisi potansiyeline sahip ülkelerden olan Türkiye'nin ortalama küresel ışıınım değeri Güneş Enerjisi Potansiyel Atlası'na (GEPA) göre kWh/m²-gün cinsinden değerlendirilmekte ve güneşlenme süresi ise saat/yıl bazında analiz edilmektedir. GEPA verileri, Türkiye'nin PV sistemlerden yüksek verim elde edebilecek uygun koşullara sahip olduğunu işaret etmektedir. Ülkenin farklı bölgelerinde güneşlenme süresi ve ışıınım seviyesi farklılık göstermesine rağmen, özellikle Güneydoğu Anadolu, İç Anadolu ve Akdeniz Bölgeleri güneş enerjisi üretimi açısından en avantajlı bölgeler arasında yer almaktadır (GEPA 2025).

Güneş enerjisinden elektrik üretimi, çeşitli fiziksel, çevresel ve teknolojik değişkenlere bağlı olarak farklı ölçeklerde gerçekleşmektedir. En önemli değişkenlerden olan, kullanılan PV panel teknolojisi ve sistem konfigürasyonu, elektrik üretim kapasitesinin belirlenmesinde kritik bir rol oynamaktadır. Monokristalin, polikristalin ve ince film PV paneller, farklı ışıınım seviyelerinde değişken performanslar sergileyerek toplam üretim potansiyelini etkilemektedir. Özellikle yeni nesil perovskit ve çift yüzeyli (bifacial)

paneller, hem ön hem de arka yüzeylerinden gelen ışınmı soğurarak daha yüksek üretim kapasitelerine ulaşabilmektedir (Rahman vd. 2025). Panel türüne ek olarak, sistemin eğim açısı ve yönlendirilmesi de toplam enerji üretimini doğrudan etkilemektedir (Barbón vd. 2025).



Şekil 2.1 Türkiye'nin güneş enerjisi potansiyeli atlası (GEPA) (GEPA 2025).


Güneş enerjisi sistemlerinin toplam üretimini belirleyen bir diğer temel faktör çevresel koşullardır. Bulutluluk oranı, bağıl nem, hava kirliliği, hava basıncı ve sıcaklık gibi meteorolojik değişkenler, güneş panellerine ulaşan ışınm miktarını ve dolayısıyla elektrik üretimini büyük ölçüde etkilemektedir (Arseven ve Çınar 2025b). Yüksek sıcaklıklar, PV hücrelerde iç direnç artışına neden olarak panel verimliliğini düşürmekte ve böylece toplam üretim seviyesini azaltmaktadır. Buna ek olarak, panel yüzeylerinde biriken toz, kir ve kar tabakası, ışınmın absorbe edilmesini engelleyerek enerji üretimini olumsuz yönde etkilemektedir. Benzer şekilde yüksek bağıl nemin sebep olacağı buharlaşma ile de PV panellerin üzerlerine düşecek ışınm azalmakta ve dolayısıyla üretim kapasitesi benzer oranda olumsuz etkilenmektedir.

Tüm bu değişkenler içinde en kritik ve belirleyici olanı ise güneş ışınmı süresi ve seviyesidir. PV panellerine ulaşan toplam enerji miktarını belirleyen DHI, DNI ve GHI bileşenleri, elektrik üretiminin mutlak sınırlarını belirlemektedir (Loutfi vd. 2017). Yüksek ışınm seviyelerine sahip bölgelerde, aynı teknolojik donanımına sahip sistemler çok daha yüksek üretim kapasitesine ulaşabilirken, düşük ışınm seviyelerine sahip

bölgelerde daha büyük yüzey alanları veya yoğunlaştırıcı sistemler gerekmektedir. Yıllık ortalama ışınım seviyeleri yüksek olan yerlerde, ışınım tahmini ve optimizasyonu, güneş enerjisi yatırımlarının planlanması açısından oldukça büyük önem taşımaktadır. Işınım tahmini teknikleri sayesinde, saatlik, günlük ve mevsimsel bazda enerji üretim projeksiyonları yapılabilmekte, böylece sistemlerin optimum seviyede çalışması sağlanabilmektedir (Arseven ve Çınar 2023). Işınım tahmini konusu üzerinde pek çok araştırmacı oldukça farklı veriler, yöntemler ve yaklaşımlar kullanarak farklı zaman ölçekleri için çalışmalar gerçekleştirmiştir. Bu çalışmalar, Şekil 2.2'de sunulan genel kategorilere göre sınıflandırılabilir. Kullanılan belli başlı yöntemler ise Şekil 2.3'de sunulmuştur.



Şekil 2.2 Güneş ışınımı tahmini çalışmalarının genel kategorilere göre sınıflandırılması.



Şekil 2.3 Güneş ışıını tahmininde kullanılan başlıca yöntemlerin sınıflandırılması.

Gelecekte elde edilecek ışıını değeri tahmin etmek için araştırmacılar tarafından geliştirilen modellerin birçoğunda sadece geçmiş ışıını değeri modellerin girişlerinde kullanılmıştır. Moreno-Munoz ve arkadaşları (vd.) geçmiş ışıını verilerini kullanarak gelecekteki değeri tahmin etmek için bir oto regresif hareketli ortalama (Auto Regressive Moving Average-ARMA) modeli geliştirmiştir. ARMA modelinin belirlenmesi için İspanya'nın güneyindeki Cordoba'da yer alan bir istasyonda 1994-1997 yılları arasında kaydedilen beş dakikalık küresel ışıını verileri kullanılmıştır (Moreno-Munoz vd. 2008). Çolak vd. bir saatlik ışıını bir, iki ve üç saat önceden tahmin etmek için ARMA ve oto regresif entegreli hareketli ortalama (Auto Regressive Integrated Moving Average-ARIMA) modelleri oluşturmuşlardır. Elde ettikleri sonuçlar, ARMA ve

ARIMA modellerinin kısa vadeli tahminlerde etkili olduğunu göstermiştir (Colak vd. 2015). Hocaoglu vd., Eskişehir’de bulunan bir güneş gözlem istasyonundan 2005-2006 yılları arasında toplanan bir yıllık verileri kullanarak sinir ağları (Neural Network-NN) tabanlı bir model geliştirmiştir. Çalışmada, saatlik güneş ışıınımı verileri iki boyutlu görsellere dönüştürülerek NNlere giriş verisi olarak sunulmuştur (Hocaoglu vd. 2008). NNler gibi daha karmaşık modeller, doğrusal olmayan ilişkileri öğrenme potansiyeline sahip olsalar da, veri ön işleme ve model yorumlanabilirliği açısından bazı zorluklar içerebilirler. Sansa vd. ise kış mevsiminde elde edilecek güneş ışıınımını tahmin etmek için bir çalışma yürütmüştür. Araştırmada ARMA yöntemini kullanmışlar ve elde ettikleri simülasyon sonuçlarına göre, tahmin için en uygun modelin ARMA(3,3) olduğunu tespit etmişlerdir (Sansa vd. 2020). Chodakowska vd. iklimsel olarak birbirlerinden oldukça farklılık gösteren Amman (Ürdün) ve Varşova (Polonya) şehirlerinden toplanan ışıınım verilerini kullanarak aylık ve saatlik ölçeklerde ışıınım tahmini yapmak için ARIMA yöntemini kullanmışlardır. Çalışmalarının sonucunda, en doğru tahmin sonuçlarının Amman için ARIMA(1,0,0)(0,1,1)₂₄ ve ARIMA(0,0,0)(0,1,1)₁₂ modelleri ile, Varşova için ise ARIMA(1,0,0)(0,1,1)₂₄ ve ARIMA(0,0,0)(1,1,0)₁₂ modelleri ile alındığını rapor etmişlerdir (Chodakowska vd. 2023). Bununla birlikte, bu çalışmada ana odak, ışıınım verisinin kendi iç yapısına dayanmaktadır.

Güneş ışıınımı tahmin çalışmalarında birçok araştırmacı tarafından, geçmiş ışıınım değerleri ile gelecekte oluşması muhtemel değerler arasındaki doğrusal ilişkiler dikkate alınarak regresyon tabanlı (RB) modeller önerilmiştir. Arseven ve Çınar, bir yıl, altı ay, dört ay ve iki aylık test dönemleri için bir sonraki saatin güneş ışıınımını tahmin etmek için ARIMA, ridge regresyon (RR) ve lasso regresyon (LR) yöntemleri ile ayrı ayrı modeller oluşturmuşlar ve sonuç olarak tüm test periyotları için en iyi tahminlerin ARIMA(2,1,1) modeli ile elde edildiği sonucuna ulaşmışlardır (Arseven ve Çınar 2023). Bu çalışmada RR ve LR'nin de kullanılması, regresyon tabanlı modellerin ışıınım tahminindeki potansiyelini göstermekle birlikte, tek başına geçmiş ışıınım değerlerine odaklanmanın sınırlılıklarına işaret edebilir. Zira ARIMA modelinin performansının daha yüksek çıkması, zaman serisi yapısının baskın olduğunu gösterse bile, farklı değişkenlerin modellere entegrasyonu ile daha güçlü sonuçlar elde etme potansiyeli göz ardı edilmemelidir. Elsayed vd., güneş ışıınımı tahmini için en uygun modeli belirlemek

amacıyla doğrusal/sıradan regresyon (Ordinary Regression-OR), destek vektör regresyonu (Support Vector Regression-SVR), rastgele orman regresyonu (Random Forest Regression-RFR), karar ağacı regresyonu (Decision Tree Regression-DTR) ve Bayesian ridge regresyonu (BRR) gibi RB yöntemleri kullanmışlardır. Elde edilen sonuçlar, en yüksek doğruluk oranına sahip tahminlerin RFR modeli tarafından sağlandığını ortaya koymuştur (Elsayed vd. 2023). Jumin vd. ışıınımda meydana gelecek değişimleri tahmin etmek için artırılmış karar ağacı regresyonu (Boosted Decision Tree Regression-BDTR) modelini kullanmıştır. Önerilen modelin performansı, OR ve NN dahil olmak üzere geleneksel yöntemlerin performansları ile karşılaştırılmış ve çalışmanın sonuçları, önerilen BDTR modelinin diğer yarışmacı modellerden daha iyi performans sergilediğini göstermiştir (Jumin vd. 2021). Almorox ve Hontoria ise çalışmalarında İspanya'daki 16 meteoroloji istasyonundan aldıkları güneşli saatlere dayalı küresel güneş ışıını tahmini için farklı matematiksel modelleri test etmişlerdir. Üçüncü derece modeller en iyi performansı gösterse bile, doğrusal modelin sadeliği ve geniş uygulanabilirliği nedeniyle tercih edilmiştir. Ayrıca, mevsimsel bölümlenimin tahmin doğruluğunu önemli ölçüde artırmadığı da belirlenmiştir (Almorox ve Hontoria 2004). Bu çalışmalar, doğrusal olmayan ilişkileri de yakalayabilen ML tabanlı regresyon modellerinin ışıını tahmininde umut vadeden sonuçlar verdiğini göstermektedir. Ancak, bu modellerin birçoğu, geçmiş ışıını değerleri veya günün sadece güneşli saatlerinin ışıını değerleri gibi tek değişkenli veya sınırlı sayıda dışsal değişken içeren veri kümelerine odaklanmaktadır. Bu durum, ışıını üzerinde etkili olan tüm meteorolojik koşulları ve çevresel faktörleri kapsamlı bir şekilde modelleme potansiyelini kısıtlayabilir.

Sıcaklık değişkenini giriş olarak alan ve çıkış olarak güneş ışıını tahmini üreten çeşitli RB modeller de geliştirilmiştir. Sıcaklık değişkenine dayalı geliştirilen bu modellerde, yüzeye gelen dünya dışı ışıının (Extraterrestrial Radiation-ER) sıcaklık farkıyla doğrudan ilişkili olduğu varsayılmaktadır (Besharat vd. 2013). İbrahim vd. Malezya'da bir yıl boyunca toplanan günlük ortalama güneş ışıını ile minimum ve maksimum hava sıcaklığı arasındaki doğrusal ilişkiyi analiz etmişlerdir. Çalışma sonucunda, minimum ve maksimum hava sıcaklıklarının ortalaması kullanılarak oluşturulan OR modelinin güneş ışıını tahmini için uygun olduğu belirlenmiştir (İbrahim vd. 2012). Chen vd. Çin

genelindeki 48 meteoroloji istasyonundan 1994-1998 yılları arasında toplanan günlük verileri kullanarak üçü ortalama hava sıcaklığına dayalı, ikisi ise güneşlenme süresine dayalı beş farklı RB ışıınım tahmin modeli geliştirmişlerdir ve geliştirdikleri modeller ile daha doğru tahmin sonuçları elde ettiklerini raporlamışlardır (Chen vd. 2004).

Güneş ışıınımı tahmini alanında RB yöntemlerin tek değişkenli kullanımlarına odaklanan çalışmaların yanı sıra, çok değişkenli RB (MVRB) modellerin etkinliğini araştıran çalışmalar da bulunmaktadır. Jin vd. Çin'deki 69 farklı meteoroloji istasyonundan elde edilen güneş ışıınımı ve güneşlenme süresi verilerini kullanarak, GHI değerini tahmin etmek için çeşitli modeller geliştirmiştir. Çalışmada, bağıl güneşlenme süresini tek bağımsız değişken olarak kullanan üçüncü dereceden denklemler tüm istasyonlar bazında en doğru sonuçları vermiştir. Ayrıca, tüm ülke için oluşturulan genel RB denklem, istasyonlar için ayrı ayrı belirlenen denklemlere kıyasla daha düşük doğruluk göstermesine rağmen yeterli tahmin gücüne sahip bulunmuştur (Jin vd. 2005). Mecibah vd. Cezayir'deki altı şehir için güneş ışıınımını tahmin etmek amacıyla yatay yüzeye düşen aylık ortalama küresel güneş ışıınımı ile aylık ortalama güneşlenme süresi ve hava sıcaklığı verileri arasındaki ilişkiyi kullanarak 11 ampirik model geliştirmiştir. En iyi sonuçlar ikinci ve üçüncü dereceden MVRB modellerle elde edilmiş ve güneşlenme süresine dayalı modellerin hava sıcaklığına dayalı modellere kıyasla daha doğru tahminler sunduğu tespit edilmiştir (Mecibah vd. 2014). Meza ve Varas maksimum ve minimum hava sıcaklıkları arasındaki farka dayalı geliştirdikleri iki ampirik modelin performansını, sadece gün içi (gündüz) saatlerini kapsayan bir modelle karşılaştırmıştır. Sonuçlar, sıcaklık tabanlı modellerin Şili'nin normal koşullarında bulut örtüsüne dayalı modele kıyasla daha yüksek belirleme katsayısına sahip olduğunu göstermiştir. Özellikle, Allen modeli daha büyük bir belirleme katsayısına sahip olsa da atmosferik basınç verisi gerektirirken, Bristow-Campbell modeli büyük sıcaklık farklarının olduğu bölgelerde daha iyi performans sergilemiştir (Meza ve Varas 2000). Burada "sadece gün içi (gündüz) saatlerini kapsayan bir model" ifadesinin netleştirilmesi oldukça önemlidir. Birçok ışıınım tahmini çalışması doğası gereği gündüz saatlerine odaklanırken, bu ifadenin altını çizmek, modellerin tüm 24 saati kapsayan bir günlük döngüyü veya gece saatlerindeki potansiyel enerji akışlarını modelleme gibi daha geniş kapsamlı senaryoları ele almadığını belirtir. Bu durum, çalışmanın belirli bir bağlamda (gündüz ışıınımı) oldukça

başarılı sonuçlar verdiğini gösterse dahi genel bir enerji yönetim sistemi gibi sürekli veri akışına ihtiyaç duyan alanlar için modelin kapsamını sınırlayabilir. Yani, gece ve akşam saatlerine ait verilerin modele dahil edilmemesi, modelin günün tamamı için kapsamlı bir tahmin yeteneği sunmaktan ziyade, belirli bir periyoda (güneş ışığının olduğu zamanlar) odaklandığını göstermektedir. Bu, çalışmanın geçerliliğini azaltmasa bile uygulama alanının ve genellenebilirlik kapasitesinin sınırlı olduğunu ortaya koymaktadır. Akarslan vd. Türkiye'nin üç farklı şehri için geleneksel Angström-Prescott (A-P) modellerine alternatif olarak, güneş ışıınımı verilerinin geçmiş örneklerine, ER'ye ve açıklık endeksine (Clearness Index-CI) dayalı beş yeni yarı ampirik model geliştirmiştir. Modellerin test sonuçları, geliştirilen modellerin geleneksel A-P modellerine kıyasla daha yüksek doğruluk sunduğunu göstermiştir (Akarslan vd. 2018).

RB ve MVRB ışıınım tahmini modelleri; ML, DL ve optimizasyon yöntemleriyle hibritlenerek daha güçlü hale getirilebilirler. Bamisile vd. uzun vadeli GHI ve DHI tahmini için uzun kısa dönem hafıza (Long Short Term Memory-LSTM), XGBoost, çok değişkenli doğrusal/sıradan regresyon (Multivariate Ordinary Regression-MOR) ve DTR modellerinin performanslarını karşılaştırmıştır. Senegal'de belirli bir lokasyonda farklı zaman aralıkları ve iki farklı veri setiyle yapılan analizler, bu modellerin tahmin doğruluğunu değerlendirmeyi amaçlamıştır ve sonuç olarak hem GHI hem DHI için en iyi tahminler XGBoost modeli ile elde edilmiştir (Bamisile vd. 2022). Ghimire vd. günlük güneş ışıınımı tahmini için hiperparametreleri HyperOpt fonksiyonu kullanılarak optimize edilmiş bir destek vektör makinesi (SVM) tarafından takip edilen bir evrişimsel sinir ağının (Convolutional Neural Network-CNN) çift aşamalı yığılmış regresyon (Ensemble Stacked Regression-REGST) ile entegre edildiği hibrit bir model önermişlerdir. Önerdikleri modelin performansını Avustralya'da altı farklı nokta için test etmişler ve bir yıl boyunca dört mevsim verisi üzerinde yaptıkları karşılaştırmalar sonucunda önerdikleri CNN-REGST modelinin diğer ML ve DL yöntemlerine kıyasla daha yüksek doğruluk sağladığını göstermişlerdir (Ghimire vd. 2022). Kim vd. ise yaptıkları çalışmada, güneş ışıınımı tahmini için sıcaklık, bağıl nem ve toplam bulut hacmi gibi hava durumu değişkenlerini kullanarak farklı ML ve DL modellerini karşılaştırmışlardır. Çalışma kapsamında MVRB bir yöntem olan CatBoost ve DL tabanlı bir yöntem olan CNN modellerinin performansları bireysel olarak test edildikten sonra performansı artırmak

için CNN-CatBoost hibrit modeli önerilmiştir. Ayrıca, rüzgar hızı ve yağışın modele eklenmesinin doğruluk üzerindeki etkisi incelenmiş ve bu ek değişkenlerin çoğu lokasyonda tahmin performansını iyileştirdiği gözlemlenmiştir (Kim vd. 2023). Lu vd. ısıtım tahmini için LibRadtran radyatif transfer modeli (RTM) kütüphanesini MVRB ve DL tabanlı modeller olan XGBoost, rastgele orman (Random Forest-RF), MARS, çok katmanlı algılayıcı (Multi Layer Perceptron-MLP), derin sinir ağı (Deep Neural Network-DNN) ve hafif gradyan güçlendirme makinesi (Light Gradient Boosting Machine-LightGBM) ile birleştirerek hibrit modeller geliştirmiştir. Modellere aerosol optik derinliği, su buharı, ozon, tek saçılma albedosu ve kara yüzeyi albedosu gibi değişkenler giriş değişkenleri olarak verilmiştir. Sonuçlar, RTM-RF modelinin üç farklı gözlem sahasından alınan ölçümlerle karşılaştırıldığında diğer modellerden daha iyi performans gösterdiğini ortaya koymuştur (Lu vd. 2023).

Yapılan literatür incelemeleri, meteorolojik değişkenlere ek olarak, açıklık endeksi (Clearness Index-CI), güneşlenme süresi ve çeşitli başka ek veri türlerinin hibrit yöntemlerin geliştirilmesinde kullanıldığını göstermiştir. Bu ek değişkenler, modellerin performansını artırmak amacıyla genellikle normalizasyon teknikleri gibi ön işleme adımlarından geçirilmiş veya kullanılan yöntemler bu ek değişkenler kullanılarak birbirine entegre edilmiştir. Maham ve Akarslan, ısıtım tahminine yönelik olarak CI parametresini temel alan yenilikçi bir hibrit yöntem geliştirme girişiminde bulunmuşlardır. Çalışmada, tahmin modellerini ANN, doğrusal olmayan otoregresif dışsal (Nonlinear Auto Regressive Exogenous-NARX) ve RR yöntemleriyle oluşturmuşlardır. Ardından CI değeri, farklı hava koşullarına bağlı olarak üç ana kategoriye—az bulutlu, kapalı ve yoğun bulut örtüsüne sahip—ayrılmıştır. Bu metodoloji, her bir küme için en uygun modelin seçilmesi yoluyla birleştirilerek tahmin doğruluğunu iyileştirilmeyi amaçlamıştır. Bulut yoğunluğunun fazlaca olduğu iki kümede en başarılı sonuçlar ANN, bulut yoğunluğunun en az olduğu kümede ise NARX modeli kullanılarak elde edilmiştir. Son olarak her kümede en iyi sonucu veren modelleri kullanarak daha doğru tahmin sonuçları elde etmişlerdir (Maham ve Akarslan 2022). Ancak bahsedilen bu çalışmada, CI kümelerinin belirlenmesinde herhangi bir önceden tanımlanmış algoritma veya kuraldan yararlanılmamıştır. Bu durum, küme belirleme sürecinin sistematik bir temelden yoksun olduğunu ve elde edilen kümelerin doğruluk ve

güvenilirliğini potansiyel olarak sınırlandırabileceğini ortaya koymaktadır. Dolayısıyla, CI kümelerinin tanımlanmasında daha sistematik ve veri odaklı bir yaklaşım benimsenmesi, tahmin performansının iyileştirilmesi adına önemli bir adımdır. Bu bağlamda, daha sofistike kümeleme algoritmalarının kullanılması, modelin genelleme kabiliyetini artırabilir ve ıyınım tahminlerinin doğruluğunu önemli ölçüde iyileştirebilir. Lauret vd. güneş ıyınımı tahmininde normalizasyon için CI ve CSI'yi bir dizi tahmin yöntemiyle birleştirmiştir. Sonuçlar, CI'nın normalizasyon için kullanıldığı durumlarda, kullanılan yöntemle bakılmaksızın sürekli olarak daha üstün tahmin modelleri sağladığını göstermiştir (Lauret vd. 2022). Ayodele vd. geleneksel mevsimlerden bağımsız olarak verileri kümelemek için k-means algoritmasını kullanmıştır. Kümeleme sürecinde, yağışlı ve kuru mevsimler için iki küme oluşturulmuş ve farklı SVR modelleriyle yapılan tahminler daha yüksek başarı sağlamıştır (Ayodele vd. 2019). Ghofrani vd. ise güneş ıyınımı tahmininin doğruluğunu artırmak amacıyla iyileştirilmiş bir k-means algoritması ve çok katmanlı algılayıcı sinir ağı (Multi Layer Perceptron Neural Network-MLPNN) içeren yeni bir tahmin tekniğı geliştirmiştir. Önerilen kümeleme yöntemi, verileri daha güvenilir bir şekilde gruplandırarak tahmin modelinin performansını iyileştirmiştir (Ghofrani vd. 2016). Ancak, bu tür entegre modellerin karmaşıklığı, yorumlanabilirlik açısından bazı zorluklar taşıyabilir. Özellikle MLPNN gibi bir sinir ağıının işleyişi, regresyon katsayıları gibi doğrudan yorumlanabilir parametreler sunmadığı için, hangi meteorolojik değişkenlerin ıyınım tahmini üzerinde en baskın etkiye sahip olduğunu anlamak açısından yeterli bilgi sunmaz.

Güneş ıyınımı tahmin araştırmalarında, çeşitli sinyal ayrıştırma teknikleri de kullanılmıştır. Sinyal ayrıştırma tekniklerinin entegrasyonu, altta yatan dinamiklerin daha ayrıntılı bir şekilde anlaşılmasını sağlayarak daha doğru ve sağlam tahmin modellerinin geliştirilmesini kolaylaştırmaktadır. Bu teknikler, belirli zaman aralıklarında alınan güneş ıyınımı ve/veya diğer değişkenleri, zaman veya frekans alanında temsil edilebilen alt bileşenlere ayrıştırılmasına yardımcı olur. Bu tür çalışmalardan birinde, Ge vd. güneş enerjisi tahminlerinin doğruluğunu artırmak amacıyla ampirik mod ayrıştırma (Empirical Mode Decomposition-EMD) ve LSTM sinir ağlarını birleştiren hibrit bir model önermiştir. EMD tekniğı, zaman serisi verilerini daha kararlı alt bileşenlere ayırarak tahmin doğruluğunu artırırken, LSTM sinir ağları bu bileşenleri kullanarak gelecekteki

güneş ışıınımı seviyelerini daha isabetli bir şekilde tahmin etmiştir. Model, benzer güneş ışıınım profillerini kullanarak LSTM ağlarını eğitmiş ve bir saat sonrasının ışıınım değerini tahmin etme noktasında benzer çalışmalara göre yüksek doğruluk sağlamıştır (Ge vd. 2019). Eşlik vd. güneş ışıınımı verilerini alt seviyelere ayırmak için EMD tekniğini ve alt seviye sinyal tahminleri için ise SVR modellerini kullanmışlardır (Eşlik vd. 2021). Prasad vd. aylık güneş ışıınımını tahmin etmek için karınca kolonisi optimizasyonu (ACO) ve RF ile birleştirilmiş çok aşamalı çok değişkenli EMD modeli tasarlamış ve modelin performansını yeterli bulmuşlardır (Prasad vd. 2019). Kong vd. ise güneş ışıınımı tahmin performansını artırmak amacıyla EMD, kapılı tekrarlayan birim (Gated Recurrent Unit-GRU) ve dikkat mekanizmasını birleştiren yeni bir model geliştirmiştir. Model, Kalman filtresi ile gürültüsü azaltılmış zaman serisini EMD tekniğiyle alt bileşenlere ayırarak tahmin sürecini optimize etmiş ve GRU modeli ile tahminleri gerçekleştirmiştir. Karşılaştırmalı deneyler ve mevsimsel analizler sonucunda, önerilen modelin özellikle sonbahar verisinde yüksek doğruluk sağladığı ve güneş enerjili bina sistemlerinin düzenlenmesi için güvenilir bir referans sunduğu belirtilmiştir (Kong vd. 2023). Bununla birlikte, EMD'nin temel konfigürasyonu karmaşık ve birbirine bağlı değişkenleri ayırmak için yetersizdir ve bu da çok değişkenli ve dinamik yapılarla karakterize edilen veri setlerinde etkinliği kısıtlayabilir (Huang ve Wu 2008) (Wu ve Huang 2009).

Varyasyonel mod ayrıştırma (Variational Mode Decomposition-VMD) tekniği de güneş ışıınımı tahmini çalışmalarında EMD ile aynı mantıkta kullanılmıştır (Majumder vd. 2018). Ali vd. tarafından geliştirilen VMD tabanlı RF modeli, ışıınım tahmininde ML yöntemlerinin etkinliğini vurgulamıştır (Ali vd. 2021). Benzer şekilde, Band vd., çok değişkenli VMD ile DL hibrit modellerini kullanarak günlük güneş ışıınımı tahmininde önemli gelişmeler sağlamıştır (Band vd. 2024). Başka bir çalışmada ise Hao vd. tarafından önerilen VMD-LSTM modeli, LSTM ağlarını VMD ile entegre etmiş ve güneş ışıınımı akısını diğer geleneksel modellere kıyasla daha yüksek doğrulukla tahmin etmiştir (Hao vd. 2024). Bu çalışmalar, VMD'nin zaman serilerindeki karmaşık yapıları ayrıştırma yeteneği sayesinde tahmin doğruluğunu artırdığını göstermektedir. Ancak VMD ve benzeri adaptif ayrıştırma yöntemleri, parametre seçimine (örneğin, mod sayısı, dengeleme parametresi) oldukça duyarlı olabilir. Bu parametrelerin doğru şekilde

ayarlanması, genellikle deneme-yanılma yoluyla veya optimizasyon algoritmalarıyla gerçekleştirilir ki bu da hesaplama maliyetini ve model geliştirme süresini artırabilir.

Dalgacık dönüşümü (Wavelet Transform-WT) tabanlı yöntemler güneş ışıınımı tahminlerinde önemli bir rol oynamaktadır. WT'nin çok ölçekli ayrıştırma yeteneği, ışıınım ve/veya diğer verilerin farklı frekans bileşenlerine ayrılmasını ve böylece tahmin modellerinin doğruluğunun artırılmasını sağlamaktadır. Bu bağlamda, çeşitli çalışmalar WT ile desteklenen çeşitli modelleri kullanarak başarılı tahmin sonuçları elde etmiştir. Cao ve Cao geri yayımlı NN (Back Propagation Neural Network-BPNN) ve WT kullanarak tahmin çalışması gerçekleştirmişlerdir. Şangay'da ölçülen altı yıllık ışıınım değerleri, çeşitli dalgacık fonksiyonları kullanılarak üçüncü seviyede ayrıştırılmıştır ve önerilen WT-BPNN modelleri ile oldukça başarılı sonuçlar elde edilmiştir (Cao ve Cao 2006). Deo vd. çalışmalarında WT ile desteklenen bir SVM modeli kullanmıştır. Modelin başarısı, klasik SVM ile karşılaştırılarak değerlendirilmiş ve önerdikleri WT-SVM modelinin daha iyi performans gösterdiği tespit edilmiştir (Deo vd. 2016). Salisu vd. güneş ışıınımı tahmini için uyarlanabilir nöro-bulanık çıkarım sistemini (Adaptive Neuro Fuzzy Inference System-ANFIS) WT ile entegre eden hibrit bir metodoloji önermişlerdir. Tahmin için aylık ortalama güneş ışığı saatleri, bağıl nem, minimum sıcaklık ve maksimum sıcaklıktan oluşan meteorolojik değişkenler kullanılmıştır. Sürecin ilk aşamasında, ikinci seviye WT kullanılarak ayrıştırılan veri setlerinin alt sinyalleri modele giriş olarak verilmiştir. Daha sonra, güneş ışıınımı tahminleri gerçekleştirilmiştir (Sani Salisu vd. 2019). Alizamir ve arkadaşları dalgacık LSTM (WLSTM), dalgacık çok katmanlı algılayıcı ANN (WMLPANN), LSTM, çok katmanlı algılayıcı ANN (MLPANN) ve çok değişkenli uyarlanabilir regresyon spline (MARS) gibi tekniklerin ışıınım tahmin etkinliğini araştırmıştır. Sonuçlar, LSTM ve WT'yi birleştiren WLSTM'nin, çalışmada kullanılan iklim verilerine dayalı en doğru tahminleri sağladığını göstermiştir (Alizamir vd. 2023). Anupong vd. ise dalgacık ANN (WANN), ANFIS ve dalgacık SVM (WSVM) yöntemlerinin performanslarını karşılaştırmıştır ve sonuçlar dalgacık tabanlı WANN ve WSVM yöntemlerinin benzer sonuçlar ürettiğini, ancak WANN'ın biraz daha iyi performans gösterdiğini ortaya koymuştur. Ayrıca, her iki yöntem de ANFIS'e kıyasla daha yüksek doğruluk sağlamıştır (Anupong vd. 2023).

Bu tez çalışması kapsamında, kısa vadeli (bir saat sonrasının) güneş ışınlamı değerini tahmin etmeye yönelik olarak üç farklı yaklaşım geliştirilmiştir. Çalışma, özellikle kümeleme destekli dalgacık ve regresyon tabanlı yaklaşım (Cluster Assisted Wavelet and Regression Based Approach, CA-WRBA) kapsamında belirlenen, atmosferik koşullara adaptif bir hibrit modelleme stratejisi sunmaktadır. Bu yaklaşım çerçevesinde, ilk olarak CI değerleri bazlı kümeleme yapılmakta ve belirlenen farklı bulutluluk durumları (çok bulutlu, bulutlu ve az bulutlu) farklı kümelerle ayrılmaktadır. Ardından, her bir küme (yani spesifik bulutluluk durumu) için ayrı ayrı ve en uygun WT-MVRB tabanlı modeller geliştirilmektedir. Yaklaşım-3'ün temelini, her bir kümede en yüksek performansı gösteren bu özel modellerin hibrit bir yapı altında birleştirilerek genel bir tahmin modelinin oluşturulması teşkil etmektedir.

Bu özgün yaklaşım, literatürdeki çalışmaların genellikle tek bir model veya genel bir yöntemle tüm koşulları ele alma eğiliminden ayrılmaktadır. Özellikle gün içindeki dinamik bulutluluk değişimlerinin ışınlam üzerindeki etkilerini daha hassas bir şekilde yakalamak amacıyla koşula özel model seçimi ve ardından hibritleme stratejisiyle, tahmin doğruluğunu önemli ölçüde artırmayı başarmıştır. Bu sayede, farklı atmosferik durumlar için ayrı ayrı optimize edilmiş modellerin birleşimiyle daha güvenilir, sağlam ve doğru tahmin sonuçları elde edilerek literatüre önemli bir katkı sağlanmaktadır.

3. MATERİYAL ve METOT

Bölüm 3.1’de, açıklık endeksi (Clearness Index-CI) ile ilgili ayrıntılara yer verilirken, Bölüm 3.2’de tezde tahmin için kullanılan makine öğrenmesi (Machine Learning-ML) tabanlı yöntemler detaylı olarak ele alınmıştır. Bölüm 3.3’te kullanılan kümeleme algoritmaları açıklanmış, Bölüm 3.4’te dalgacık dönüşümüne (Wavelet Transform-WT) dair bilgiler verilmiş ve son olarak, Bölüm 3.’te performans analizi için kullanılan grafiksel ve istatistiksel ölçütler ayrıntılı biçimde incelenmiştir.

3.1 Açıklık Endeksi (Clearness Index-CI)

Dünya atmosferinin dışında Güneş’ten gelen toplam güneş ışıınımını ifade eden ER değeri, atmosferin etkileri (soğurma, saçılma, yansıtma vb.) dikkate alınmadan, teorik olarak Dünya yüzeyine ulaşabilecek maksimum güneş ışıınımı değerini ifade etmektedir. Bu değer, Güneş-Dünya arasındaki mesafeye ve Güneş’in anlık ışıınım gücüne bağlı olarak değişkenlik gösterebilir. Dolayısıyla, yıl içerisinde farklı zaman dilimlerinde ER değerinde değişimler gözlemlenebilir. Bir yüzeye ulaşacak saatlik ER değeri, Denklem 3.1’de verilen ampirik eşitlik yardımıyla hesaplanmaktadır (Iqbal 2012):

$$I_0 = I_{sc} \left[1 + 0.33 \cos \left(\frac{360n}{365} \right) \right] (\cos \phi \cos \theta \cos \omega + \sin \phi \sin \theta) \quad (3.1)$$

Bu denklemde:

- I_{sc} : Güneş sabiti olup değeri 1367 W/m^2 ’dir (Johnson 1954).
- ϕ : Hesaplanan noktanın enlem açısı olup -90° ile 90° arasında değişir. Bu değer, kuzey yarımkürede pozitif, güney yarımkürede ise negatiftir.
- θ : Deklinasyon açısıdır. Güneş ışıınlarının geliş doğrultusu ile ekvator düzlemi arasındaki açıdır. -23.45° ile 23.45° arasında değişir ve belirli bir tarihe göre hesaplanabilir.
- ω : Güneşin saat açısı, zamanın açısal karşılığı olup her bir saat başına 15° dönüş yapar. Öğle saatine kadar negatif, sonrasında pozitif değerlidir.
- n : Yılın kaçıncı günü olduğunu veren değerdir.

Saatlik ER deęerleri, yılın farklı dönemlerinde güneşlenme süreleri ve açıları ile deęişiklik göstermektedir. Özellikle mevsimsel deęişiklikler, δ deęerindeki farklılıklar ve gün uzunlukları nedeniyle saatlik ER deęerlerinde belirgin dalgalanmalar gözlenmektedir. Ancak herhangi bir yılın aynı tarih ve saatinde her yıl için hesaplanan ER deęerleri olarak aynı olmaktadır. Bu durum, yıllık güneş enerjisi potansiyelinin belirlenmesinde önemli bir referans noktası oluşturmaktadır. Saatlik ER deęerlerindeki bu mevsimsel ve teorik dalgalanmalar, bölgesel güneş enerjisi potansiyelinin deęerlendirilmesinde kritik bir rol oynamaktadır. Bu tür analizler, belirli bir bölge için enerji planlaması ve yenilenebilir enerji kaynaklarının optimizasyonunda önemli bilgiler sunmaktadır.

CI parametresi, atmosferin güneş ışıını üzerindeki etkisini nicel olarak belirleyen önemli bir parametredir. Güneş enerjisi ile ilgili yapılan modellemelerde, PV sistemlerinin verimliliklerinin deęerlendirilmesinde ve iklim araştırmalarında CI parametresi çeşitli amaçlarla yaygın olarak kullanılmaktadır. En temelde CI deęeri, atmosferik koşulların güneş ışıınıını ne ölçüde zayıflattığını göstererek, bulut örtüsü, aerosol yoğunluğu, su buharı ve hava kirlilięi gibi atmosferik faktörlerin güneş enerjisi potansiyeli üzerindeki etkisini analiz etmeye olanak tanımaktadır. Saatlik CI deęeri Denklem 3.2 yardımıyla hesaplanmaktadır:

$$K_t = \frac{GHI}{I_{sc} \cdot \cos(\theta_z)} \quad (3.2)$$

Burada; $\cos(\theta_z)$ güneş ışıınıının dünyaya geliş açısidir.

Atmosferin ne denli açık/bulutsuz olduęunun bir derecesi olan CI deęeri 0 ila 1 arasında deęerler alır. Bu deęer, atmosferin güneş ışıınıı üzerindeki etkisini deęerlendirerek, belirli bir bölgedeki güneş enerjisi potansiyelinin belirlenmesine yardımcı olur. CI deęeri 1'e yaklaştıkça, atmosferin daha şeffaf olduęu ve güneş ışıınıının büyük ölçüde yüzeye ulaştığı anlaşılır. Bu durum genellikle açık ve bulutsuz hava koşullarında görülür. CI deęeri 0'a yaklaştıkça, atmosferik engellemelerin (bulut örtüsü, sis, aerosol yoğunluğu, hava kirlilięi gibi) güneş ışıınıını büyük oranda azalttığı ve yüzeye ulaşan ışıınıın

minimum seviyeye indiđi anlařılır. Bu durum, yođun bulutluluk veya k t  hava kořullarıyla iliřkilidir.

3.2 Kullanılan Makine  đrenmesi Tabanlı Y ntemler

Bu b l mde, tez  alıřması kapsamında g neř ıřınımı tahmini i in uygulanan ML tabanlı regresyon y ntemleri detaylandırılmaktadır.  alıřmada,  zellikle  ok deđiřkenli veri setlerinin karmařık iliřkilerini modelleme yetenekleri nedeniyle  ne  ıkan iki farklı MVRB y ntem  ok deđiřkenli ridge ve lasso regresyon y ntemleri kullanılmıřtır. Bu y ntemler sayesinde, kullanılan verilerden anlamlı  r nt ler  ıkararak tahmin dođruluđunun ve g venilirliđinin artırılması hedeflenmiřtir.

3.2.1  ok Deđiřkenli Ridge Regresyon Y ntemi

Ridge regresyon (RR), dođrusal regresyonda (OR)  oklu dođrusal bađlantı (multicollinearity) problemiyle bařa  ıkmak i in geliřtirilmiř bir ML tabanlı y ntemdir.  oklu dođrusal bađlantı, bađımsız deđiřkenler arasında y ksek korelasyon olduđunda regresyon katsayılarının dengesizleřmesine yol a maktadır. RR y ntemi ise bu durumu kontrol altına almak amacıyla modele bir ceza terimi eklemek suretiyle katsayıları k   lt rek modeli daha kararlı hale getirir (Hoerl ve Kennard 1970).

RR y ntemi ile tahmin modeli oluřturulurken, verilerin bir kısmı modelin eđitimi i in ayrılırken, geri kalan kısmı ise geliřtirilecek modelin dođruluđunu deđerlendirmek amacıyla test verisi olarak kullanılır. Bu yaklařım, eđitim verilerine daha az uyum sađlayan, ancak genelleme kabiliyeti daha y ksek bir model geliřtirmeyi hedefler. Modelin eđitim verisine ařırı uyum sađlamasının (overfitting)  n ne ge mek amacıyla, RR y ntemi modele bir ceza terimi ekler. Bu ceza terimi, modelin varyansını azaltarak test verilerinde daha tutarlı ve g venilir sonu lar elde edilmesine katkı sađlar.

RR modelinde, ceza terimi regresyon katsayılarının b y kl đ n  sınırlayarak parametrelerin ařırı deđerler almasını engeller. Bu sınırlama,  zellikle  oklu dođrusal bađlantının mevcut olduđu durumlarda modelin daha kararlı hale gelmesini sađlar. Sonu  olarak, modelin karmařıklıđı azalır ve test verisi  zerindeki genelleme kapasitesi artar.

Bu durum, modelin eğitim verilerine mükemmel uyum sağlama çabasını azaltarak, doğrulama aşamalarında daha başarılı sonuçlar ortaya koyar. Bu bağlamda, RR yöntemi eğitim verilerinde hata oranını minimize etmeye değil, test verisi üzerindeki hata oranını dengelemeye odaklanır. Bu özellik, modelin farklı veri kümelerinde daha iyi performans göstermesini sağlar ve aşırı öğrenme sorununu azaltır (Marquardt ve Snee 1975). Dolayısıyla, RR modeli daha az karmaşık ancak genelleme yeteneği yüksek tahminler sunar. Tek değişkenli RR (Univariate Ridge Regression-URR) modelinin parametrelerini belirlemek için Denklem 3.3'te verilen eşitlik kullanılır.

$$\tilde{X}_i = \beta_0 + \beta_1 X_i + \lambda(\beta_1)^2 \quad (3.3)$$

Burada; $\tilde{X}_i$ model ile gerçekleştirilen tahminin değerini, β_0 doğrunun dikey eksenini kestiği değeri, β_1 doğrunun eğitimi katsayısını, λ ceza miktarını belirleyen ceza katsayısını ve $\lambda(\beta_1)^2$ URR'de kullanılan ceza terimini ifade etmektedir.

URR modelinden farklı olarak, çok değişkenli RR modeli (MRR) birden fazla bağımsız değişken içeren regresyon analizlerinde kullanılmaktadır. Bu model özellikle, bağımsız değişkenler arasında yüksek korelasyon olduğunda regresyon katsayılarının aşırı büyümesini engelleyerek modelin istikrarını artırır ve modelin temel denklemi Denklem 3.4'te verilen şekilde ifade edilir (Saleh vd. 2019):

$$\tilde{X}_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \lambda \sum_{j=1}^p \beta_j^2 \quad (3.4)$$

URR modelinde yalnızca bir bağımsız değişken bulunurken, MRR modeli p sayıda bağımsız değişkeni kapsayarak daha kompleks veri setleri üzerinde uygulanabilmektedir.

URR denkleminde farklı olarak MRR denklemindeki; $\beta_1, \beta_2, \dots, \beta_p$ değerleri bağımsız değişkenlerin regresyon katsayılarına, $X_{i1}, X_{i2}, \dots, X_{ip}$ gerçekleştirilmiş her bir gözlem için bağımsız değişkenlere ve $\sum_{j=1}^p \beta_j^2$ ise MRR modelinin ceza terimine karşılık gelmektedir.

MRR modeli, bağımsız değişkenler arasındaki yüksek korelasyondan kaynaklanan problemleri azaltır ve regresyon katsayılarının dengesizleşmesini önleyerek çoklu doğrusal bağlantıya karşı direnç gösterir. MRR modeli, ceza terimi sayesinde model varyansını azaltarak genelleme kabiliyetini artırır. Buna karşın MRR modeli bünyesindeki ceza terimi sayesinde model varyansını azaltarak genelleme kabiliyetini artırır. Birden fazla bağımsız değişkenin kullanılmasıyla MRR modelinde katsayıların aşırı büyük değerler alması beklenmediğinden, modelin tahmin sonuçları URR modeline kıyasla daha tutarlı olmaktadır. Bu durum, özellikle yüksek boyutlu veri setlerinde katsayıların dengesizleşmesini önleyerek modelin daha sağlam bir yapıya kavuşmasını sağlar. Küçük örneklem büyüklüğüne sahip veya çok sayıda bağımsız değişken içeren veri setlerinde regresyon katsayılarının aşırı büyümesi tahmin hatalarını artırabilir.

Ceza katsayısı olan λ değerinin optimize edilmesi de oldukça önemlidir. Seçilecek λ parametresinin küçük değerleri modelin OR modeline yakınsamasına neden olurken, büyük değerleri ise katsayıları aşırı küçülterek modelin önemli değişkenleri göz ardı etmesine yol açabilir. Bu nedenle, λ parametresi çapraz doğrulama (cross-validation) gibi yöntemlerle optimize edilerek modelin en iyi performansı göstermesi sağlanır. Sonuç olarak, MRR, bağımsız değişkenler arasında yüksek korelasyon bulunan veri setlerinde güvenilir ve dengeli tahminler elde etmek için kullanılan etkili bir ML tabanlı yöntemdir.

3.2.2 Çok Değişkenli Lasso Regresyon Yöntemi

Lasso regresyon (LR), OR'de çoklu doğrusal bağlantı (multicollinearity) problemini çözmek ve modelin genelleme kapasitesini artırmak amacıyla kullanılan bir başka düzenlileştirme (regularization) yöntemidir (Tibshirani 1996). RR'deki gibi, model katsayılarını küçültmek için bir ceza terimi ekler; ancak, RR'den farklı olarak L_1 normunu kullanır. Bu yöntem, özellikle değişken seçimi yaparak modelin daha sade ve yorumlanabilir hale gelmesini sağlamasıyla öne çıkar. Tek değişkenli LR (Univariate Lasso Regression-ULR), yalnızca bir bağımsız değişken içeren regresyon analizlerinde kullanılan temel LR modelidir. ULR modelinin matematiksel gösterimi Denklem 3.5'te verilmiştir (van Wieringen 2015, Arseven ve Çınar 2023).

$$\tilde{X}_i = \beta_0 + \beta_1 X_i + \lambda |\beta_1| \quad (3.5)$$

URR'den farklı olarak ULR'de L_1 normuna dayalı olan $\lambda|\beta_1|$ ceza terimi kullanılır. Bu da bağımsız değişkenin regresyon katsayısını sıfıra çekebilir. Böylece, veri setinde anlamlı olmayan değişkenleri elimine ederek modelin aşırı öğrenmesi önlenmiş olur.

Tek değişkenli model olan ULR'nin genişletilmiş hali olan çok değişkenli lasso regresyonu (MLR), birden fazla bağımsız değişken içeren regresyon analizlerinde kullanılır. Modelin temel denklemi Denklem 3.6'da verilen şekilde ifade edilir (Saleh vd. 2019):

$$\tilde{X}_t = \beta_0 + \beta_1 X_{t1} + \beta_2 X_{t2} + \dots + \beta_p X_{tp} + \lambda \sum_{j=1}^p |\beta_j| \quad (3.6)$$

MLR'nin en önemli özelliği, bazı regresyon katsayılarını sıfıra eşitleyerek değişken seçimi yapabilmesidir. Böylece model, önemsiz değişkenleri dışlayarak daha sade ve yorumlanabilir hale gelir. Yine MLR modelin aşırı karmaşıklığını azaltarak genelleme kapasitesini artırır. Gereksiz değişkenlerin elimine edilmesi, test verisinde daha iyi performans elde edilmesini sağlar. Ayrıca, MRR'nin aksine, MLR yalnızca katsayıları küçültmekle kalmaz, aynı zamanda belirli katsayıları sıfıra çekerek daha kompakt modeller oluşturur.

3.3 Dalgacık Dönüşümü

Dalgacık dönüşümü (WT), herhangi bir sinyalin zaman ve frekans bileşenlerini birlikte inceleme imkânı sunan güçlü bir matematiksel araçtır. Geleneksel analiz yöntemlerinden farklı olarak WT, sinyali farklı ölçeklerde parçalayarak hem zaman hem de frekans çözünürlüğü sağlar. Bu yönüyle, sinyallerin yerel özelliklerini belirlemek için oldukça uygun bir tekniktir (Sifuzzaman vd. 2009).

WT, belirli bir ana dalgacık fonksiyonu (mother wavelet) kullanarak sinyali farklı ölçeklerde analiz eder. Ana dalgacık fonksiyonu, dönüşüm sürecinin temel yapı taşıdır ve analiz edilen sinyalin zaman-frekans uzayında nasıl temsil edileceğini belirler. Bu fonksiyon, belirli ölçekleme ve kaydırma işlemleri uygulanarak türetilen yeni dalgacık

fonksiyonları oluşturur. WT yöntemi, ana sinyalin belirli örüntülerle ifade edilen alt sinyallere ayrıştırılmasını gerektirir. Bu desenler, tanımlanmış bir dalgacık formu boyunca büyüme ve daralma sergileyerek zaman içinde bir değişim sürecinden geçer. Ana sinyal çeşitli ana dalgacık fonksiyonlarıyla karşılaştırılarak dalgacıklara dönüştürülür. Bu işlem, sinyalden ilgili özelliklerin ve bilgilerin çıkarılmasını sağlar. Matematiksel olarak, bir dalgacık gerçek zamanlı ekseninde $(-\infty, \infty)$ tanımlanan bir fonksiyon $(\psi(t))$ olarak ifade edilir. $\psi(t)$ fonksiyonu Denklem 3.7 ve 3.8’de verilen iki koşulu her zaman sağlamak zorundadır (Percival ve Walden 2000).

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.7)$$

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt = 1 \quad (3.8)$$

WT’de analiz için farklı dalgacık türleri kullanılmaktadır. Her dalgacık fonksiyonu belirli özelliklere sahiptir ve farklı uygulamalar için geliştirilmiştir. Seçilecek dalgacık fonksiyonu, temel fonksiyonların uzayda ne ölçüde kompakt bir biçimde konumlandırıldığı ile ayrıştırma işlemi için ne kadar uygun olduğu arasındaki dengeyi sağlamalıdır (Graps 1995). En yaygın dalgacık türleri şunlardır:

- Haar Dalgacığı: En basit ve en eski dalgacık fonksiyonlarından biridir. Sinyalleri keskin ayrımlarla bölerek analiz yapar.
- Daubechies (db) Dalgacıkları: db dalgacıkları fraktal yapıya sahiptir (Graps 1995). Bu dalgacıklar enerjiyi oldukça verimli bir şekilde yoğunlaştıran ortogonal dalgacıklardır (Vonesch vd. 2007).
- Meyer Dalgacığı: Sürekli ve türevlenebilir bir dalgacık fonksiyonudur. Fourier dönüşümü ile uyumlu bir yapıya sahiptir ve geniş spektral bantlara sahip sinyallerin analizinde kullanılır (Meyer 1992).
- Meksika Şapkası Dalgacığı: İkinci türevi alınmış bir Gauss fonksiyonundan türetilmiştir ve kenar tespiti gibi uygulamalarda sıkça kullanılır.
- Coiflet Dalgacıkları: Özellikle pürüzsüz sinyallerin sıkıştırılması ve analizinde etkili olup, az sayıda dalgacık katsayısıyla yüksek doğrulukta bir gösterim sunar. Belirli bir simetriyi ve enerji yoğunlaştırmasını sağlayan ikili kesirli filtre

katsayılarına sahiptir. Bu yapı, sinyallerin daha etkin analiz edilmesine ve daha düşük bilgi kaybına olanak tanır (Wei 1998).

- Symlet Dalgacıkları: db dalgacıklarının daha simetrik versiyonlarıdır ve distorsiyonu minimize etmek için geliştirilmiştir.

Güneş ışıınımı sinyalleri, genellikle zamanla değişen ve durağan olmayan bir yapıya sahiptir. Durağan olmayan sinyaller bağlamında, bileşenlerin zaman içindeki değişen frekanslardaki analizi kritik öneme sahiptir. Bu noktada, sinyal bileşenleri, WT yöntemi kullanılarak farklı frekanslardaki bileşenlerine ayrıştırılabilir (Arseven ve Çınar 2025a). WT zamansal olarak iki ana gruba ayrılır: sürekli dalgacık dönüşümü (Continuous Wavelet Transform-CWT) ve ayrık dalgacık dönüşümü (Discrete Wavelet Transform-DWT).

3.3.1 Sürekli Dalgacık Dönüşümü

CWT, bir sinyalin zaman-frekans çözünürlüğünü sağlamak amacıyla kullanılan güçlü bir dönüşüm yöntemidir. CWT, Fourier dönüşümünün sınırlamalarını aşarak sinyalin frekans bileşenlerinin zaman boyunca nasıl değiştiğini ortaya koyar. Bu dönüşüm, özellikle değişken frekans içeriğine sahip sinyallerin analizinde etkili olup zaman-frekans çözünürlüğü açısından klasik yöntemlere kıyasla büyük avantajlar sunar. Herhangi bir ana dalgacık fonksiyonu ψ kullanılarak CWT ile bir dizi alt dalgacık ($\psi_{\tau,s}$) türetilir. Alt dalgacıklar, ana dalgacığın ölçeklenmesi ve kaydırılmasıyla elde edilir (Denklem 3.9):

$$\psi_{\tau,s} = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right) \quad (3.9)$$

Burada; s ölçekleme veya genişleme faktörü olup dalgacığın genişliğini kontrol ederken, τ zaman kaydırma parametresi dalgacığın konumunu belirler. Eğer s büyürse, dalgacık genişler ve düşük frekans bileşenlerini analiz eder; küçük s değerleri ise yüksek frekanslı bileşenleri ortaya çıkarır. Zaman kaydırma işlemi ise dalgacığın zaman eksenindeki konumunu belirler (Aguiar-Conraria ve Soares 2014).

CWT'nin en önemli avantajlarından biri, sinyalin yerel frekans bileşenlerini detaylı bir şekilde ortaya koymasındır. Bununla birlikte, CWT'nin en temel sorunlardan biri, işlem yükünün oldukça yüksek olmasıdır. CWT, tüm ölçek ve kaydırma parametreleri için sürekli bir dönüşüm gerçekleştirdiğinden hesaplama maliyeti oldukça fazladır. Bu durum, özellikle büyük veri setleri veya gerçek zamanlı uygulamalar için ciddi bir performans sınırlaması oluşturabilir. Ayrıca, dalgacık fonksiyonunun seçimi analiz sonuçlarını doğrudan etkilediğinden uygun dalgacığın belirlenmesi karmaşık bir süreçtir. Bu sebeplerle, CWT'nin avantajlarına rağmen, pratik uygulamalarda işlem verimliliği açısından bazı optimizasyonlarının yapılması gerekmektedir.


3.3.2 Ayrık Dalgacık Dönüşümü

Esasen CWT'nin bir alt kümesi olan DWT, belirli ölçekler ve zaman aralıkları dahilinde dönüşümü kolaylaştırır. DWT bağlamında bir dalgacık, sonlu bir veri setine uygulanabilen ortogonal bir fonksiyon olarak tanımlanabilir. İşlevsel olarak, dönüşüm fonksiyonunun ortogonal olması, dönüşümden iki kez geçirilen bir sinyalin değişmeden kalması ve giriş sinyalinin bir dizi ayrık zamanlı örnekten oluştuğu varsayımı, bu yöntemi güçlü bir analiz aracı haline getirmektedir (Sundararajan 2016). Bu özellikleri DWT'nin, sinyallerin hem zaman hem de frekans bileşenlerinin hassas bir şekilde incelenmesine olanak tanır ve yüksek hesaplama verimliliği sağlar (Edwards 1991).

DWT, bir sinyali hem zaman hem de frekans alanlarında analiz eden ve hem düşük hem de yüksek frekanslı bileşenleri ortaya çıkaran matematiksel bir araçtır. Bu da DWT'nin yapısında kullanılan alçak geçiren filtre (Low Pass Filter-LPF) ve yüksek geçiren filtreler (High Pass Filter-HPF) kullanılarak gerçekleştirilir. DWT'de kullanılan LPF, sinyalin düşük frekanslı bileşenlerini, yani daha kapsamlı ve daha az karmaşık özelliklerini ayırt etmek için kullanılır. Bu, sinyalin genel yapısını ve uzun vadeli eğilimlerini tespit etmek için kullanılır. HPF ise sinyalin daha fazla ayrıntı ve hızlı değişim ile karakterize edilen yüksek frekanslı bileşenlerini tanımlamak için kullanılır.

DWT ile analiz edilen bir sinyal, farklı ölçeklerde ayrıştırılarak detay ve yaklaşık isimleri verilen bileşenlere ayrılmaktadır. Yaklaşık bileşenler (approximation coefficients), düşük frekanslı içerikleri temsil eden ve sinyalin genel yapısını belirleyen bileşenlerdir. Bu

bileşenler LPF aracılığıyla elde edilir ve sinyalin uzun vadeli eğilimlerini ve makro düzeydeki özelliklerini yansıtır. Öte yandan, detay bileşenler (detail coefficients), yüksek frekanslı bileşenleri içeren ve sinyalin daha ince yapısal detaylarını temsil eden bileşenlerdir. HPF kullanılarak hesaplanan bu bileşenler, sinyaldeki kısa vadeli değişimleri, ani geçişleri ve yüksek frekanslı dalgalanmaları analiz etmeye olanak tanır. DWT'nin bu yapısı, sinyalin farklı frekans bantlarında incelenmesini sağlarken aynı zamanda zamansal çözünürlüğünü de koruyarak, hem genlik hem de zaman bazında daha ayrıntılı bir analiz yapılmasına yardımcı olur. Bu nedenle, detay ve yaklaşık bileşenlerin birlikte değerlendirilmesi, özellikle gürültü azaltma, sıkıştırma ve özellik çıkarımı gibi uygulamalarda önemli avantajlar sunmaktadır. Şekil 3.7'de sunulan DWT ayrıştırma ağacı bir sinyalin n . dereceden DWT kullanılarak ayrıştırılması sürecini görselleştirmektedir.



Şekil 3.1 DWT ayrıştırma ağacı (Arseven ve Çınar 2025b).

Şekil 3.1’de başlangıçta S ile gösterilen giriş sinyali, LPF ve HPF kullanılarak filtreleme işlemine tabi tutulur. LPF ile filtrelenen bileşen, yaklaşık bileşen A_1 olarak adlandırılır ve sinyalin düşük frekanslı içeriğini temsil eder. HPF ile filtreleme sonucu ise detay bileşeni D_1 elde edilir ve sinyalin yüksek frekanslı, hızlı değişen içeriklerini barındırır. Bu işlem iteratif olarak devam eder. Yaklaşık bileşenler LPF ve HPF filtrelerinden geçirilerek, daha düşük frekans seviyelerine ulaşan yeni yaklaşık bileşenler ve daha fazla detay bileşenleri elde edilir. Matematiksel olarak ise Denklem 3.10 kullanılarak yaklaşık katsayıları, Denklem 3.11 kullanılarak ise detay katsayıları belirlenir.

$$A_n(k) = \sum_n x(n) \cdot \phi_{j,k}(n) \quad (3.10)$$

$$D_n(k) = \sum_n x(n) \cdot \psi_{j,k}(n) \quad (3.11)$$

Burada;

- $A_n(k)$, yaklaşık katsayıları olup $\phi_{j,k}(n)$ ölçekleme fonksiyonu ile hesaplanır.
- $D_n(k)$, detay katsayıları olup $\psi_{j,k}(n)$ dalgacık fonksiyonu ile elde edilir.
- j ölçek seviyesini ve k ise zaman kaymasını ifade eder.

Her ayrıştırma seviyesinde yaklaşık ve detay bileşenlerine ayrılan sinyal, alt seviyelerde daha ayrıntılı analiz edilerek hem global hem de lokal özelliklerin belirlenmesini mümkün kılmaktadır (Strang ve Nguyen 1996). Sonuç olarak DWT, hem genlik hem de zaman bazında ayrıntılı bir analiz yapılmasına olanak tanır. Özellikle gürültü azaltma, sinyal sıkıştırma ve özellik çıkarımı gibi uygulamalarda büyük avantajlar sunar.

3.4 Kümeleme Algoritmaları

Kümeleme, gözetimsiz öğrenme yöntemlerinden biri olup, veri setindeki örnekleri benzerliklerine göre kümelere ayırmayı amaçlar. Kümeleme algoritmaları, önceden etiketlenmemiş veriler üzerinde yapısal örüntüleri ortaya çıkarmak için kullanılır. En yaygın kullanılan algoritmalar arasında k-ortalamlar (k-means), Kernel k-ortalamlar (Kernel k-means), hiyerarşik kümeleme ve yoğunluk tabanlı kümeleme (DBSCAN) yer

almaktadır. Her bir algoritmanın, veri yapısına ve uygulama amacına göre avantajları, dezavantajları ve sınırlılıkları bulunmaktadır ve bu algoritmalar, fen bilimlerinden sosyal bilimlere, biyoinformatiğe kadar oldukça geniş bir yelpazede uygulanmaktadır.

Işınım tahmini çalışmalarında kümeleme algoritmaları, benzer meteorolojik koşulları taşıyan zaman dilimlerinin veya coğrafi bölgelerin gruplandırılmasına yardımcı olarak model doğruluğunu artırmak için kullanılmaktadır. Ayrıca, kümeleme yöntemleri yardımıyla aşırı uç koşulların daha doğru bir şekilde modellenmesi mümkün olmakta ve bu da özellikle hibrit tahmin sistemlerinin performansını artırmaktadır. Bu tür yaklaşımlar, hem istatistiksel hem de fiziksel modelleme teknikleriyle birleştirildiğinde, ıslanım tahminlerinde önemli iyileştirmeler sağlamaktadır.

Bu bölümde, tez kapsamında CI değerlerinin kümelenmesinde kullanılan manuel yöntem ile k-means ve Kernel k-means algoritmalarına ilişkin genel teorik bilgilere yer verilmektedir.

3.4.1 Manuel Yöntem

Tezde kullanılan CI değerlerini kümelemek için ilk olarak manuel kümeleme yöntemi kullanılmıştır. Bu yaklaşım, herhangi bir matematiksel formülasyon ya da algoritmik bir yapı gerektirmeyen, tamamen öznel değerlendirmelere dayanan stokastik bir süreçtir. Manuel kümeleme, araştırmacının gözlemlerine, deneyimlerine ve sezgisel çıkarımlarına bağlı olarak gerçekleştirilir. Bu yöntemde, nesnel bir standart veya tutarlı bir karar mekanizması bulunmadığından, elde edilen kümelerin doğruluğu ve tekrar üretilebilirliği sınırlı olabilir. Dolayısıyla, yöntemin temel dezavantajı, sonuçların yorumlayıcıya bağlı olarak değişebilme ihtimali nedeniyle tutarlılık ve güvenilirlik açısından belirsizlikler taşımasıdır.

Bununla birlikte, manuel kümeleme yöntemi özellikle veri boyutunun sınırlı olduğu, kümelerin belirgin özellikler sergilediği veya nicel analizlerin yeterli açıklık sunmadığı durumlarda faydalı bir ön analiz aracı olarak değerlendirilebilir. Araştırmacının alan bilgisi ve deneyimi, bu yöntemin uygulanmasında kritik rol oynamaktadır. Ancak, öznel yargılara olan yüksek bağımlılığı nedeniyle, manuel kümeleme yöntemi çoğunlukla nicel

ve tekrarlanabilir algoritmik yöntemlerle desteklenmeli ya da karşılaştırmalı olarak kullanılmalıdır. Bu yaklaşım, analiz sürecinde daha dengeli ve güvenilir sonuçların elde edilmesine katkı sağlayabilir.

3.4.2 K-Means Algoritması

En popüler ve basit kümeleme algoritmalarından biri olan k-means 1955 yılında literatüre girmiştir. k-means algoritması 70 yıl önce önerilmiş olmasına ve o zamandan beri binlerce kümeleme algoritması yayınlanmış olmasına rağmen halen daha yaygın bir şekilde kullanılmaktadır (Jain 2010). Bu algoritma, gözetimsiz öğrenme yöntemleri arasında en yaygın kullanılan tekniklerden biri olup, veri madenciliği, istatistiksel modelleme ve ML alanlarında geniş bir uygulama alanına sahiptir. Bu algoritmanın temel amacı, benzer özellikler sergileyen verileri aynı grupta (kümede) toplayarak, birbirine benzeyen veri noktalarının aynı kümede yer almasını; farklı özellikler taşıyanların ise ayrı kümelere atanmasını sağlamaktır.

k-means algoritması, her bir kümenin merkezini temsil eden merkez noktalarına (centroid) dayanmaktadır. Veriler, bu merkezlere olan uzaklıklarına göre k adet kümeye yerleştirilir. Temel prensip, her bir veri noktasının ait olduğu küme merkezine olan öklidyen uzaklığının karesinin toplamını minimize etmektir. Bir diğer ifadeyle bu algoritma her bir veri noktasının en yakın küme merkezine olan mesafesinin karesini minimize eden bir amaç fonksiyonunu minimize etme amacıyla çalışır (James 2013). Bahsi geçen amaç fonksiyonu, Denklem 3.12'deki şekilde tanımlanmaktadır:

$$J = \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_i\|^2 \quad (3.12)$$

Bu denklemde, k kümelerin sayısını, C_i i. kümeyi, x_j j. veri noktasını ve μ_i ise i. kümenin merkezini temsil etmektedir. $\|x_j - \mu_i\|^2$ terimi, x_j veri noktası ile μ_i küme merkezi arasındaki öklidyen mesafenin karesini ifade eder.

Algoritmanın başlangıç aşamasında, kullanıcı tarafından belirlenen k adet merkez noktası rastgele bir şekilde seçilir. Daha sonra, her bir x_j , merkez noktası kendisine en yakın olan kümeye atanır. Bu atama işlemi Denklem 3.13'te verilen şekilde yapılır:

$$C_l = \{x_j : \|x_j - \mu_l\|^2 \leq \|x_j - \mu_i\|^2 \forall i, 1 \leq i \leq k\} \quad (3.13)$$

Veri noktaları kümelere atandıktan sonra ikinci aşamada, her bir küme için yeni merkez noktaları hesaplanır. Bu merkezler, ait olduğu kümeye ait tüm veri noktalarının aritmetik ortalaması alınarak elde edilir. Küme merkezlerinin güncellenme işlemleri ise Denklem 3.14'teki eşitlik yardımıyla gerçekleştirilir:

$$\mu_l = \frac{1}{|C_l|} \sum_{x_j \in C_l} x_j \quad (3.14)$$

Veri noktalarının kümelere atanması işlemi ve merkezlerin yeniden hesaplanması, küme merkezleri ve veri atamaları sabitleninceye kadar tekrarlanır. Algoritma böylece en uygun kümelemeyi gerçekleştirmeyi amaçlar. k-means algoritmasının avantajlarından biri, büyük veri setleri üzerinde hızlı bir şekilde uygulanabilmesi iken, en büyük dezavantajı ise başlangıçta seçilen merkez noktalarına ve kümelerin sayısına duyarlı olmasıdır. Ayrıca, karmaşık ya da doğrusal olmayan veri yapılarında sınırlı performans gösterebilir.

3.4.3 Kernel K-Means Algoritması

Bu tezde CI değerlerinin kümeleme sürecinde kullanılan üçüncü algoritma, geleneksel k-means algoritmasının geliştirilmiş bir versiyonu olan kernel k-means algoritmasıdır. Kernel k-means algoritması, doğrusal olmayan veri yapılarını daha etkili şekilde modelleyebilmek amacıyla çekirdek (kernel) yöntemlerini kullanır. Bu yöntem, verileri doğrudan kümelere ayırmak yerine, verileri yüksek boyutlu bir özellik uzayına dönüştürerek verilerin bu uzayda kümelenmesini sağlar. Bu dönüşüm, $\phi(x)$ ile tanımlanan bir fonksiyon aracılığıyla gerçekleştirilir (Yakut 2012). Veri noktaları arasındaki benzerlikler, bir çekirdek fonksiyonu yardımıyla hesaplanır (Denklem 3.15):

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (3.15)$$

Burada $K(x_i, x_j)$ ifadesi, kernel fonksiyonunun temel tanımını verir. Bu ifade, x_i ve x_j veri noktalarının, doğrusal olmayan bir dönüşüm fonksiyonu olan Φ aracılığıyla yüksek boyutlu bir özellik uzayına yansıtıldığını ve bu uzaydaki iç çarpımlarının (dot product) hesaplandığını gösterir. Ancak bu dönüşüm açık bir şekilde gerçekleştirilmez. Bunun yerine, kernel hilesi (kernel trick) olarak adlandırılan yöntem sayesinde, bu iç çarpım, yalnızca orijinal uzaydaki x_i ve x_j değerleri üzerinden hesaplanabilir. Bu sayede yüksek boyutlu uzaya geçmeden, aynı uzayda çalışılıyormuş gibi benzerlik ölçümleri yapılabilir. Kernel fonksiyonu bu bağlamda, iki veri noktası arasındaki benzerliğin dolaylı bir ölçüsünü sunar ve böylece doğrusal olmayan veya doğrusal bir şekilde değişiklik göstermeyen veri yapılarını daha etkili şekilde modellemeye olanak tanır.

Klasik k-means'ten farklı olarak, kernel k-means algoritmasında kümeleme ölçütü olan maliyet fonksiyonu (J), doğrudan çekirdek matrisi kullanılarak tanımlanır. Denklem 3.16'da verilen formül, her bir veri noktasının kendi kümesindeki diğer noktalarla olan ilişkisini kernel benzerlikleri üzerinden hesaplar:

$$J = \sum_{k=1}^K \sum_{x_i \in C_k} \left(K(x_i, x_i) - \frac{2}{|C_k|} \sum_{x_j \in C_k} K(x_i, x_j) + \frac{1}{|C_k|^2} \sum_{x_i, x_j \in C_k} K(x_i, x_j) \right) \quad (3.16)$$

Burada , C_k k. kümeyi, $|C_k|$ ise bu kümeye ait veri sayısını temsil etmektedir.

Sonuç olarak her bir veri noktası, kernel fonksiyonu ile hesaplanan uzaklık esas alınarak en yakın kümeye atanır. Kümelerin merkezleri (ya da temsil değerleri), yine çekirdek matrisinden türetilen benzerlik ortalamalarıyla güncellenir. Bu işlem, kümeleme kriteri olan J amaç fonksiyonunu minimize edilene kadar tekrarlanır. Bu algoritmanın en büyük avantajı, klasik yöntemlerin başarısız olduğu doğrusal olmayan veya doğrusal değişiklikler göstermeyen veri kümelerinde daha başarılı sonuçlar verebilmesidir. Ancak bu avantaj, hesaplama maliyetinin oldukça artmasına neden olabilir. Dahası doğru kernel seçimi yapılmadığı takdirde, algoritma istenilen performansı gösteremeyebilir.

Bu tez kapsamında kullanılan üç farklı kümeleme yaklaşımı olan manuel kümeleme, k-means ve kernel k-means algoritmaları; veri işleme yaklaşımları, matematiksel temelleri,

hesaplama karmaşıklıkları ve doğrusal olmayan veri yapılarıyla başa çıkabilme kapasiteleri açısından önemli farklılıklar göstermektedir. Her bir yaklaşımın CI değerlerinin kümelenmesi sürecindeki rolünü daha bütüncül bir şekilde değerlendirebilmek amacıyla, kullanılan yöntemlerin öne çıkan yönleri sistematik biçimde analiz edilmiştir. Bu kapsamda hazırlanan Çizelge 3.1, ilgili algoritmaların temel özelliklerini, avantaj ve dezavantajlarını karşılaştırmalı olarak sunmaktadır. Tablo, yöntemlerin karar verme mekanizmaları, modelleme kapasitesi, uygulama zorluk derecesi ve doğrusal olmayan veri setlerine karşı dayanıklılık gibi boyutlarda farklılıklarını açık biçimde ortaya koymaktadır.

Çizelge 3.1. Kullanılan kümeleme algoritmalarının karşılaştırması.

Özellik/ Algoritma	Manuel Kümeleme	K-Means	Kernel K-Means
Temel Yaklaşım	Uzman yorumuna ve sezgisel gözleme dayalıdır.	Veri noktalarını en yakın merkezlere göre k adet kümeye ayırır.	Verileri yüksek boyutlu uzayda kernel fonksiyonlarıyla kümelendirir.
Matematiksel Model	Belirli bir model yoktur.	Öklidyen mesafeye dayalı merkezleme ve minimizasyon yapar.	Kernel fonksiyonlarıyla benzerlik temelli merkezleme ve minimizasyon yapar.
Uygulama Karmaşıklığı	Düşük (Algoritmik süreç içermez.)	Orta (Hızlı ve kolay uygulanabilir.)	Yüksek (Kernel matrislerinin hesaplanması nedeniyle daha fazla kaynak gerektirir.)
Doğrusal Olmayan Veri	Başarısız	Yetersiz	Başarılı
Avantajları	Oldukça esnektir ve işlem yükü gerektirmez.	Basit, hızlı ve büyük veri setlerinde etkilidir.	Karmaşık ve doğrusal olmayan yapıları tanımlamada güçlüdür.
Dezavantajları	Öznel kararlar, düşük tekrar üretilebilirlik	Küresel kümelere duyarlılık, lokal minimumda takılma riski	Kernel seçiminde hassasiyet, yüksek hesaplama maliyeti

3.5 Performans Analizi

Işınım tahmini çalışmalarında, model performansını değerlendirmek amacıyla oldukça çeşitli istatistiksel ve grafiksel ölçütler kullanılmaktadır. Bu bölümün devamında, söz konusu bu ölçütlere ilişkin detaylara yer verilmektedir. İlk alt bölümde, kullanılan istatistiksel performans ölçütlerine dair teorik bilgiler ve ilgili formüller sunulmaktadır. Devamında yer alan ikinci alt bölümde ise, kullanılan grafiksel değerlendirme yöntemleri açıklanarak bu yöntemlerin yorumlanmasına ilişkin genel bilgiler verilmektedir.

3.5.1 İstatistiksel Performans Ölçütleri

Model değerlendirme kriterleri arasında sıkça kullanılanlardan birisi Akaike bilgi kriteridir (AIC) (Akaike 1998). İlk olarak Hirotugu Akaike tarafından literatüre kazandırılan AIC, daha yüksek olasılık değerlerine sahip modelleri tercih etme eğilimindedir. AIC, modelin karmaşıklığını (parametre sayısını) cezalandırarak daha basit modellerin tercih edilmesine yardımcı olmaktadır. Böylece aşırı uyumun (overfitting) önlenmesine katkıda bulunmaktadır (Vrieze 2012). AIC, modeller arasında seçim yaparken regresyon ve zaman serisi analizi de dahil olmak üzere çeşitli ML tabanlı yöntemlerle en uygun modellerin belirlenmesi için kullanılan bir kriterdir. Ayrıca AIC, model karmaşıklığı ve uyumunu dengelediği için model seçimi için kritik bir araç olarak kabul edilir. Bununla birlikte, AIC tek başına bir değerlendirme aracı olarak yeterli değildir; bu nedenle, diğer model değerlendirme yöntemleri ve istatistiksel performans ölçütleriyle birlikte kullanılması önerilir. AIC değerini hesaplamak için kullanılan formül Denklem 3.17’de verilmiştir (Özdemir):

$$AIC = 2k - 2\ln(\hat{L}) \quad (3.17)$$

Burada; k modelin parametre sayısını ve $\hat{L}$ ise modelin maksimum olabilirlik (maximum likelihood) fonksiyonunun tahminini vermektedir. Model seçimi noktasında, en küçük AIC değerine sahip model tipik olarak en uygun model olarak kabul edilir ve bu değer doğruluk ile basitlik arasındaki optimum dengeyi temsil etmektedir. Tez kapsamında AIC değerlerinin kullanılmasının amacı, DWT’nin kullanıldığı yaklaşımda hangi ayrıştırma seviyesinin daha doğru sonuçlar vereceğini öngörmeye çalışmaktır.

Tez kapsamında oluşturulan modellerin performans analizleri için kullanılan bir diğer istatistiksel metrik kök ortalama karesel hata (RMSE) ölçütüdür. RMSE değeri tahmin hatalarının büyüklüğünü aynı birim cinsinden ifade etmesi nedeniyle, hata düzeyinin doğrudan yorumlanmasına olanak tanımaktadır. Özellikle sürekli değerlerin tahmin edildiği regresyon modellerinde yaygın olarak RMSE değerine başvurulmaktadır. Daha düşük bir RMSE değeri, oluşturulan tahmin modelinin tahmin performansının yüksek olduğunu ve modelle yapılan öngörülerin gerçek değerlere oldukça yakın olduğunu göstermektedir. Ancak RMSE, hata karelerinin ortalaması üzerinden hesaplandığı için, büyük hata değerlerine karşı duyarlıdır. Bu durum, modelin birkaç uç tahmin hatası (outlier) üretmesi halinde, RMSE değerinin orantısız bir şekilde artmasına neden olabilir. Bu nedenle RMSE, özellikle veri setinde aykırı değerlerin bulunduğu durumlarda yanıltıcı olabilir ve modelin geneline dair hatalı bir izlenim verebilir. RMSE değerinin az sayıda aykırı değere karşı daha hassas olması, doğrudan mutlak hata varyansına bağlanabilir (Brassington 2017). RMSE değeri Gaussian hatalar olduğunda en önemli öngörü sağlar (Hodson 2022). RMSE değerinin hesaplanmasında kullanılan formül Denklem 3.18’de verilmiştir (Hodson 2022).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\tilde{x}_i - x_i)^2}{n}} \quad (3.18)$$

Burada, n gözlem sayısını, x_i i anında ölçülmüş gerçek değeri, $\tilde{x}_i$ ise i anında model tarafından tahmin edilen değeri temsil etmektedir.

Normalize edilmiş RMSE (NRMSE) değeri, klasik RMSE değerinin, veri kümesinin ölçeğinden bağımsız hale getirilmesini sağlayan bir hata ölçütüdür. NRMSE değeri, RMSE'nin veri kümesindeki maksimum ve minimum değerleri arasındaki farka (yani tüm verilerin yer aldığı aralığın uzunluğuna) bölünmesiyle elde edilir. Böylece, modelin tahmin hataları, verinin genel dağılımına göre değerlendirilmiş olur. Bu normalleştirme işlemi ile farklı ölçeklerdeki veri setleri ya da modeller arasında karşılaştırma yapılması kolaylaştırılmış olur. NRMSE formülü Denklem 3.19’da verilmiştir.

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (\hat{x}_i - x_i)^2}{n}}}{\max(x_i)} \quad (3.19)$$

Normalize edilmiş ortalama mutlak hata (NMAE), model tahmin hatalarının mutlak değerlerinin ortalamasının, veri setinin ölçeğine göre normalize edilerek ifade edilmesini sağlayan bir diğer istatistiksel değerlendirme ölçütüdür. Tıpkı RMSE'nin normal (Gaussian) dağılımlı hatalar altında en uygun kestirimi sağlaması gibi, NMAE de Laplace dağılımlı hatalar altında en uygun kestirimciyi temsil eder. Bu durumda mutlak sapmaların (L1 normu) minimize edilmesi, maksimum olabilirlik tahminini verir. Dolayısıyla hata dağılımının ağır kuyruklara sahip olduğu ya da uç değerlerin bulunduğu durumlarda, normal dağılım varsayımı bozulduğunda, NMAE kullanımı RMSE'ye kıyasla daha sağlam ve uygun bir tercih olabilir (Willmott ve Matsuura 2005). Daha düşük bir NMAE değeri, modelin gerçek değerlere daha yakın öngörülerde bulunduğunu gösterir ve dolayısıyla tahmin performansının yüksekliğine işaret eder. NMAE değerinin hesaplanmasında kullanılan formül Denklem 3.20'de verilmiştir:

$$NMAE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{x}_i - x_i|}{\max(x_i)} \quad (3.20)$$

Tezde belirlenen modellerle yapılan tahminlerin ne denli başarılı olduğunu ortaya koymak adına kullanılan ölçütlerden bir diğeri ise %R² metriğidir. Bu ölçüt, bir modelin tahmin ettiği değerlerin, gözlenen değerler üzerindeki toplam varyansı ne oranda açıkladığının değerini verir. Regresyon analizlerinde en sık kullanılan değerlendirme kriterlerinden biri olan %R², 0 ile 100 arasında bir değer alır. Daha yüksek %R² değeri, modelin tahminlerinin gözlenen değerlerle daha yüksek uyum içinde olduğunu ve modelin veriyi daha iyi açıkladığını gösterir. Ancak, en yüksek %R² değerine sahip model her zaman en iyi modeldir denilemez. Çünkü bu metrik yalnızca doğrusal ilişkiyi dikkate alır ve modelin tahmin doğruluğu hakkında doğrudan bilgi vermez. Bu nedenle %R² değeri, diğer hata ölçütleriyle birlikte değerlendirildiğinde daha anlamlı ve güvenilir bir model değerlendirmesi sağlar. Bu metrik için kullanılan hesaplama formülü Denklem 3.21'de verilmiştir (Arseven ve Çınar 2025b):

$$\%R^2 = 100. \left(1 - \frac{SSE}{SST}\right) \quad (3.21)$$

Burada, SSE modelin tahminleri ile gerçek gözlemler arasındaki farkların karelerinin toplamını, SST gerçek değerlerin ortalamasından sapmalarının karelerinin toplamını ifade eder.

Tez kapsamında gerçekleştirilen modelleme süreçlerinde oluşturulan ısıtım tahmin modellerinin başarısını objektif biçimde değerlendirmek amacıyla çeşitli istatistiksel performans ölçütlerinden yararlanılmıştır. Bu ölçütler, hem modelin veriye ne ölçüde uyum sağladığını hem de aşırı öğrenme gibi istenmeyen durumların önüne geçilip geçilmediğini tespit etmeye yönelik olarak tercih edilmiştir. Özellikle tahmin hatalarının büyüklüğünü, oranını ve modelin açıklayıcılığını değerlendiren bu metrikler; model karşılaştırmalarında karar verme sürecine önemli katkılar sunmaktadır. Bu tezde kullanılan temel istatistiksel değerlendirme ölçütlerinden her birinin sunduğu avantajlar ve bunların sınırlılıklarının karşılaştırmalı olarak sunulduğu özet tablo Çizelge 3.2’de yer almaktadır.

Çizelge 3.2. Kullanılan istatistiksel performans ölçütlerinin karşılaştırması.

Ölçüt	Avantajları	Sınırlılıkları
AIC	Aşırı uyumu engeller ve model seçimi için uygundur.	Tek başına kullanılması yeterli değildir ve göreceli bir ölçüttür.
RMSE	Hata büyüklüğünü açıkça gösterir.	Aykırı değerlere fazla duyarlıdır.
NRMSE	Ölçekten bağımsız karşılaştırma yapılmasına olanak tanır.	Aykırı değerlere fazla duyarlıdır.
NMAE	Aykırı değerlere karşı daha az duyarlıdır ve mutlak hatalara dayandığı için daha istikrarlı sonuçlar verir.	Normalizasyon işlemi veri dağılımına bağlı olarak yanıltıcı olabilir.
%R²	Varyans açıklama oranı üzerinden model başarısını verir.	Sadece doğrusal ilişkileri dikkate alır ve çok yüksek değerlerde aşırı uyuma işaret edebilir.

3.5.2 Grafiksel Değerlendirme Yöntemleri

Işınım tahmin çalışmalarında oluşturulan tahmin modelleriyle ne denli başarılı tahminler yapıldığını görselleştirmek adına birçok grafik kullanılabilir. Bu bağlamda tez kapsamında genel geçer karşılaştırmalı grafiklerin yanı sıra radar grafikleri ve Taylor diyagramlarına başvurulmuştur.

Radar grafikleri, çoklu performans kriterlerinin aynı düzlemde görselleştirilmesine olanak tanıyan çok eksenli diyagramlardır. Bu grafikler sayesinde, her bir modelin farklı performans metriklerine göre ne ölçüde başarılı olduğu tek bir grafik üzerinde karşılaştırmalı olarak incelenebilir. Radar grafikleri, özellikle RMSE, NMAE, NRMSE ve $\%R^2$ gibi ölçütlerin birlikte değerlendirildiği durumlarda model performansının daha bütüncül bir şekilde ele alınmasına olanak tanır. Modelin ilgili eksenlerdeki değerlerine göre oluşturulan çokgensel alan, modelin genel başarısını görsel olarak temsil eder. Alanın büyüklüğü ve şekli, modelin farklı metriklerde gösterdiği performansa göre değişiklik gösterir. Böylece, radar grafiklerine bakılarak modellerin güçlü ve zayıf yönleri kolaylıkla ayırt edilebilir.

Taylor diyagramları ise model performansını korelasyon katsayısı, standart sapma ve RMSE olmak üzere üç temel ölçüt üzerinden aynı düzlemde değerlendirmeye olanak tanıyan özel bir grafik türüdür. Bu diyagramlarda, tahmin modellerinin gerçek veriye olan benzerliği hem doğruluk hem de tutarlılık bağlamında görselleştirilmektedir. Taylor diyagramının merkez noktası gözlemlenen değerleri temsil ederken, her bir model diyagram üzerinde konumlandırılarak korelasyon katsayısına göre açısal yerleşimi, standart sapmasına göre uzaklığı ve RMSE değerine göre konumu belirlenir. Bu yapı sayesinde, farklı modellerin hem bireysel hem de görelî performansları hızlı ve etkili bir biçimde karşılaştırılabilir. Ayrıca, özellikle benzer doğruluk düzeyine sahip birden fazla modelin, varyans ve hata büyüklüğü gibi diğer faktörler açısından ayrıştırılmasına da olanak tanır.

Tez kapsamında radar grafikleri ve Taylor diyagramları, oluşturulan farklı model yapılandırmalarının performanslarının çok yönlü olarak değerlendirilmesi amacıyla birlikte kullanılmıştır. Bu grafiksel analizler sayesinde, yalnızca tek bir metrik üzerinden

değil, çoklu performans göstergeleri temelinde yapılan değerlendirmelerle, hangi model yapılandırmalarının ıřınım tahmininde daha etkili sonuçlar ürettiğı kapsamlı bir şekilde ortaya konmuştur. Böylece, sayısal ölçütlerle elde edilen model başarı skorları görsel olarak da desteklenmiş ve model seçimine ilişkin karar verme süreci daha nesnel bir zemine oturtulmuştur.



4. ÖNERİLEN IŞINIM TAHMİN YAKLAŞIMLARI

Tez kapsamında bir saat sonrasının ışıınım değeri tahmin etmek amacıyla üç farklı yaklaşım (Yaklaşım-1, Yaklaşım-2 ve Yaklaşım-3) benimsenmiştir. Bu yaklaşımların oluşturulmasına ilişkin detaylar bu bölümde alt başlıkların içeriklerinde sunulmuştur.


4.1 Temel Regresyon Tabanlı Yaklaşım

Benimsenen ilk modelleme stratejisi olan temel regresyon tabanlı yaklaşım (Basic Regression Based Approach-BRBA) kapsamında, ABİ'den elde edilen saatlik formattaki ışıınım, ortalama sıcaklık ve bağıl nem verileri kullanılarak çok değişkenli regresyon temelli tahmin modelleri oluşturulmuştur. Bu süreçte, MRR ve MLR yöntemlerinden yararlanılmıştır. Amaç, farklı meteorolojik değişken kombinasyonlarının, sonraki saate ait güneş ışıınımı değerlerini ne ölçüde doğru tahmin edebildiğini ortaya koymaktır.

BRBA kapsamında oluşturulan model versiyonları ise şu şekilde yapılandırılmıştır:

- Versiyon-1 (V1): Giriş değişkeni olarak yalnızca ışıınım ve ortalama hava sıcaklığı verileri kullanılmıştır. Model, bir saat öncesinin bu iki değişkene ait değerlerini kullanarak bir sonraki saate ait ışıınım değerini tahmin etmektedir. Bu versiyon, ortalama hava sıcaklığının ışıınımla olan etkileşimini modelleme ve test etme açısından da önem taşımaktadır.
- Versiyon-2 (V2): Oluşturulan bu versiyonda ışıınım ve bağıl nem verileri model girişine verilmiştir. Bu versiyonda da yine bir saat önceki değerler esas alınarak sonraki saat için ışıınım tahmini gerçekleştirilmiştir. V2, özellikle havanın doymuş nem oranının ışıınım tahmini üzerindeki etkisini bağımsız olarak değerlendirmeye olanak tanımaktadır.
- Versiyon-3 (V3): Işıınım, ortalama hava sıcaklığı ve bağıl nem değişkenlerinin tamamı giriş değişkeni olarak modele sunulmuştur. Her bir değişkenin bir saat öncesine ait değeri temel alınarak, takip eden saatin ışıınım miktarı tahmin edilmiştir. Bu yapı, çoklu etkileşimlerin birlikte modellendiği daha kapsamlı bir versiyonu temsil etmektedir.

Söz konusu bu üç giriş seti kombinasyonları aracılığıyla, farklı meteorolojik değişken kombinasyonlarının tahmin performansı üzerindeki etkisi karşılaştırmalı olarak değerlendirilmiştir. Bu değerlendirme sayesinde, yalnızca belirli değişkenlerin değil, aynı zamanda bu değişkenlerin birlikte kullanılması durumunda model başarısı ayrıntılı olarak analiz edilmiştir. Ayrıca, modellerin giriş çeşitliliğine bağlı olarak nasıl tepki verdiği, hata düzeylerinin hangi değişken kombinasyonlarında azaldığı/arttığı ve korelasyon değerlerinin nasıl/ne yönde değiştiği gibi kritik performans ölçütleri grafiksel ve sayısal analizlerle ortaya konmuştur. Böylece, BRBA kapsamındaki modelleme süreci sadece doğruluk temelli değil, aynı zamanda değişken duyarlılığı açısından da bütüncül bir şekilde değerlendirmeye tabi tutulmuştur. BRBA yaklaşımına ait genel prensibi ve modelleme sürecine ilişkin şematik gösterim Şekil 4.1’de verilmiştir.



Şekil 4.1 Temel regresyon tabanlı yaklaşım (Basic Regression Based Approach-BRBA) için oluşturulmuş prensip şeması (Arseven ve Çınar).


4.2 Dalgacık ve Regresyon Tabanlı Yaklaşım

İkincil modelleme stratejisi olan dalgacık ve regresyon tabanlı yaklaşım (Wavelet and Regression Based Approach-WRBA) kapsamında, saatlik ısınım, ortalama hava sıcaklığı ve bağıl nem verileri, ön işlemeye tabi tutulmuştur. Ön işleme sürecinde tek boyutlu DWT tekniği ile farklı seviyelerde ayrıştırma gerçekleştirilmiştir. Bu dönüşüm ile her bir değişken, düşük frekanslı (yaklaşık bileşen) ve yüksek frekanslı (detay bileşenleri) bileşenlere ayrılarak daha ayrıntılı bir yapıda temsil edilmiştir. Elde edilen bu alt sinyaller, orijinal verinin hem kısa süreli dalgalanmalarını hem de genel eğilimlerini daha açık biçimde modellemeye olanak tanımıştır. Dalgacık dönüşümünde, verilerin genel yapıları ile yüksek düzeyde benzerlik gösterdiği tespit edilen Daubechies 10 (db10) dalgacığı tercih edilmiştir. db10 dalgacığının seçilmesindeki temel gerekçe, kullanılan meteorolojik zaman serilerinin frekans dağılımları ve sinyal pürüzsüzlüğü açısından db10 dalgacığıyla yapısal uyum göstermesidir. Böylece, dönüşüm sonrası elde edilen bileşenlerin veri setlerinin içsel dinamiklerini daha doğru yansıtmaları hedeflenmiştir. Ayrıca, her bir değişken için 1., 2., 3. ve 4. seviyelerde tek boyutlu DWT ayrıştırması gerçekleştirilmiştir. Buradaki temel amaç, hangi seviyedeki tahmin başarısının daha başarılı olacağını belirleyerek en uygun ayrıştırma düzeyini tespit etmektir. Böylece, sadece DWT uygulamakla kalınmamış, aynı zamanda frekans çözünürlüğü ile model doğruluğu arasındaki ilişki de sistematik biçimde analiz edilmiştir.

Farklı seviyelerde tek boyutlu DWT ile ayrıştırma işlemlerinin sonrasında, her bir ayrıştırılmış sinyal bileşeni (yaklaşık ve detay bileşenleri) için bağımsız MRR ve MLR modelleri geliştirilmiştir. Böylece, hem düşük hem de yüksek frekanslı bilgi içeriği taşıyan bileşenlerin tahmin gücü ayrı ayrı test edilerek değerlendirilmiştir. Her bir model, kendi seviyesindeki alt sinyalleri kullanarak sonraki saate ait ısınım değerini tahmin edecek şekilde eğitilmiştir. Oluşturulan bu modelleme yapısı sayesinde, klasik modellemede genellikle göz ardı edilen, sinyalin yüksek frekans bileşenlerinde yer alan kısa süreli ve küçük ölçekli dalgalanmalar da modele dahil edilerek analiz edilebilmiştir.

İkinci strateji olan WRBA kapsamında da, ilk strateji olan BRBA'da tanımlanan V1, V2 ve V3 giriş değişkeni kombinasyonlarına sadık kalınmış; her bir versiyonun değişken

kombinasyonları, bu kez DWT ile ayrıştırılmış alt sinyaller üzerinde uygulanarak değerlendirme yapılmıştır. Bu yaklaşım sayesinde, değişken kombinasyonlarının yalnızca ham verilerde değil, aynı zamanda ayrıştırılmış frekans bileşenleri düzeyinde de model performansına etkisi karşılaştırmalı olarak incelenmiştir. WRBA stratejisi sayesinde, veri ayrıştırmasının tahmin doğruluğuna katkı sağlayıp sağlamadığı belirlenmiş ve ML tabanlı regresyon modellerinin frekans temelli veri temsilleriyle olan etkileşimi değerlendirilmiştir. WRBA yaklaşımına ilişkin prensip şeması Şekil 4.2’de sunulmuştur.



Şekil 4.2 Dalgacık ve regresyon tabanlı yaklaşım (Wavelet and Regression Based Approach- WRBA) için oluşturulmuş prensip şeması.


4.3 Kümeleme Destekli Dalgacık ve Regresyon Tabanlı Yaklaşım

Kümeleme destekli dalgacık ve regresyon tabanlı yaklaşım (Cluster Assisted Wavelet and Regression Based Approach, CA-WWRBA), belirlenen iki numaralı strateji olan WRBA'nın devamı niteliğinde olup, hava koşullarının tahmin performansı üzerindeki etkisini daha ayrıntılı biçimde analiz etmeye yönelik olacak şekilde geliştirilmiştir. Bu yaklaşımda, atmosferik koşulların çeşitliliği dikkate alınarak, veriler belirli hava durumu sınıflarına ayrılmış ve her bir sınıf için özelleştirilmiş modelleme süreçleri uygulanmıştır. Böylece, DWT-MRR ve DWT-MLR modellerinin farklı meteorolojik koşullar altındaki tahmin başarıları karşılaştırmalı olarak değerlendirilmiştir.

CA-WWRBA stratejisi kapsamında ilk olarak, saatlik CI değerleri, aralarında manuel yöntem, k-means algoritması ve kernel k-means algoritmasının bulunduğu üç farklı kümeleme algoritması ile kümelere ayrılmıştır. Her bir algoritma, CI verilerini az bulutlu (SC), bulutlu (C) ve çok bulutlu (MC) olmak üzere üç kümeye ayıracak biçimde yapılandırılmıştır. Bu sınıflandırma işlemi ile havanın açıklık-kapalılık düzeyleri belirlenmiş ve böylece ışıınım tahmini açısından önemli olan meteorolojik ayrışmalar dikkate alınmaya çalışılmıştır. Kümeleme adımını takiben, WRBA kapsamında geliştirilen DWT-MRR ve DWT-MLR modelleri, her bir küme için ayrı ayrı uygulanmıştır. BRBA kapsamında V1, V2 ve V3 olarak tanımlanan giriş değişken kombinasyonları CA-WRBA için de korunarak, her hava koşulu sınıfı altında bu kombinasyonlara ait model performansları detaylı biçimde analiz edilmiştir. Bu sayede, her bir meteorolojik senaryo için en yüksek tahmin başarısını sağlayan modelin ve giriş değişkeni kombinasyonlarının tespit edilmesi amaçlanmıştır.

CA-WRBA'nın özgün yönlerinden biri, CI değerlerine de frekans temelli ayrıştırma uygulanmasıdır. Bu kapsamda, CI zaman serisi db10 dalgacı kullanılarak birinci seviyede tek boyutlu DWT ile ayrıştırılmış, ardından bu ayrıştırılmış sinyaller için belirlenen MRR modelleri kullanılarak bir saat sonrasına ait CI değerleri tahmin edilmiştir. Tahmin edilen bu CI değerleri, ilgili saatin hangi bulutluluk kümesine ait olduğunu belirlemek amacıyla kullanılmıştır. Sürecin devamında kümelendirme sonucuna göre, belirlenen kümede en iyi performans gösteren model ve giriş

kombinasyonu belirlenerek, o saate ait ışınlm tahmini gerekleřtirilmiřtir. Benimsenen bu hibrit modelleme yapısı sayesinde, mevcut atmosferik kořul belirlendikten sonra, yalnızca o kořula zg ğrenme bařarısı yksek olan model devreye alınmıř ve bylece daha isabetli tahminler gerekleřtirilmiřtir. Bu yapı, klasik modelleme yaklařımlarında gz ardı edilebilecek kořul farklılıklarını dikkate almıř ve genel tahmin doğruluğunda anlamlı bir artış elde edilmesini mmkn kılmıřtır. Sonuç olarak, CA-WRBA yalnızca zaman serilerinin frekans temelli ayrıştırılmasıyla sınırlı kalmayıp, aynı zamanda kořul duyarlı, dinamik ve adaptif bir tahmin mekanizması sunmuřtur. Bu srecin iřleyiřine dair genel prensip řeması, řekil 4.3'te ayrıntılı olarak sunulmuřtur.



řekil 4.3 Kmeleme destekli dalgacık ve regresyon tabanlı (Cluster Assisted Wavelet and Regression Based Approach, CA-WRBA) iin oluřturulmuř prensip řeması.

5. BULGULAR

Tez kapsamında, üç farklı yaklaşım kullanılarak geliştirilen ışıınım tahmin modellerinin oluşturulmasında kullanılan veri setlerine ilişkin genel bilgiler Bölüm 5.1’de sunulmuştur. Bir saat sonrasında alınacak güneş ışıının tahmini amacıyla altı aylık ve bir yıllık test dönemleri için belirlenen üç farklı yaklaşım (BRBA, WRBA ve CA-WRBA) kullanılarak geliştirilen tahmin modellerinin performans değerlendirmesi gerçekleştirilmiştir. Bunun için öncelikle, WRBA ve CA-WRBA prosedürlerinin işletilmesi için gerekli olan tek boyutlu DWT yöntemi uygulanarak, hepsi saatlik formatlarda olan güneş ışıını, ortalama hava sıcaklığı, bağıl nem ve CI verileri farklı seviyelerde ayrıştırılmıştır. Devamında, her bir yaklaşım kapsamında oluşturulan giriş veri seti versiyonları (V1, V2 ve V3) için eğitim verileri kullanılarak MRR ve MLR modelleri geliştirilmiştir. CA-WRBA özelinde, CI değerleri esas alınarak üç farklı hava açıklık durumu için kümeler tanımlanmış ve bu doğrultuda CI değerlerinin kümeleme işlemleri gerçekleştirilmiştir. Bu kümeler içerisinde, her bir küme için en yüksek tahmin başarımını sağlayan model ve veri seti versiyonları tespit edilmiştir. Son aşamada ise, geliştirilen bu üç yaklaşımın tahmin performansları karşılaştırmalı olarak değerlendirilmiştir.

Bu bölümde, öncelikle tüm veri setleri ile CI değerlerinin tek boyutlu DWT ile ayrıştırılma süreçlerine ilişkin teknik detaylar sunulmuş; ardından tüm yaklaşımlarda tüm giriş seti versiyonları için kullanılan MRR ve MLR modellerinin belirlenme süreci ile bu modellere ait parametreler açıklanmıştır. Sonrasında saatlik CI değerlerine dayalı olan kümeleme süreçleri ayrıntılı olarak aktarıldıktan sonra son olarak her bir yaklaşım kapsamında elde edilen nihai tahmin sonuçları detaylı şekilde ortaya konulmuştur.


5.1 Kullanılan Veri Setleri

Tez kapsamında oluşturulan ışıınım tahmin modelleri için Afyonkarahisar şehrinde bulunan Meteoroloji 5. Bölge Müdürlüğü’nün ABİ istasyonundan toplanan saatlik ışıınım, sıcaklık ve bağıl nem verileri kullanılmıştır. Deniz seviyesinden 1034 metre yükseklikte,


37°45' ve 39°17' kuzey enlemleri ile 29°40' ve 31°43' doğu boylamları arasında yer alan bu şehir, Ege Bölgesi'nde yer almasına rağmen tipik Ege ikliminden farklı biraz daha farklı iklimsel özelliklere sahiptir. 37°45' ve 39°17' kuzey enlemleri ile 29°40' ve 31°43' doğu boylamları arasında yer alan Afyonkarahisar'da genel olarak yıl boyunca düşük bağıl nem ve mevsimlere göre değişen ortalama sıcaklıklarla karakterize edilen karasal iklim özellikleri görülmektedir.

1991-2020 yılları arasında yapılan ölçümler sonucunda Afyonkarahisar'da yıllık ortalama güneşlenme süresinin yaklaşık 7 saat olduğu bilinmektedir. Yaz aylarında ise günlük güneşlenme süresi Türkiye ortalamasının üzerindedir (Türkiye'nin yıllık ortalama güneşlenme süresi günlük 7.2 saattir). Kış aylarında ise karasal iklimin etkisiyle bulutlu gün sayısı nispeten yüksektir. Ayrıca, şehir merkezindeki yıllık güneş ışıınımı potansiyeli 1600-1700 kWh/m² olarak kaydedilmiştir (Demirkol ve Cunkaş 2014). Kış aylarında soğuk hava kütlelerinin etkisi nedeniyle bölgede soğuk hava koşulları hakimdir. Yaz aylarında ise Batı Anadolu ve Afyonkarahisar çevresinde tropikal hava kütlelerinin etkisi görülmektedir. Karasallığın etkisi Afyonkarahisar'da yaz ve kış dönemleri ile gece ve gündüz arasında önemli sıcaklık değişikliklerine neden olmaktadır. 1991-2020 yılları arasındaki resmi veriler incelendiğinde, Afyonkarahisar'da yıllık ortalama sıcaklığın 11.3 °C olduğu görülmektedir. Karasal iklim özellikleri gösteren şehirde yıllık ortalama bağıl nem oranı yaklaşık %64'tür (Kervankıran 2011).


Tezdeki modellerde kullanılan güneş ışıınımı, hava sıcaklığı ve bağıl nem veri setleri, ABİ'den temin edilmiştir. Coğrafi koordinatları 38°44'16"N ve 30°33'37"E olan meteoroloji istasyonundan alınan veri setleri, 1 Ocak 2018 ile 31 Aralık 2021 tarihleri arasındaki dört yıllık dönemi kapsamakta olup, veri setlerinin her biri toplam 35.064 saatlik ölçümlerden oluşmaktadır. İstasyona ait konum bilgileri ve bölgesel dağılımı görselleştirmek amacıyla Şekil 5.1'de yer bulduru haritası verilmiştir. Ayrıca, ışıınım tahmin modellerinde giriş verileri olarak kullanılan dört yıllık saatlik güneş ışıınımı (G), ortalama hava sıcaklığı (T) ve bağıl nem (H) değerlerini gösterir grafikler ise sırasıyla Şekil 5.2, 5.3 ve 5.4'te sunulmuştur. Çizelge 5.1'de ise tezde kullanılan veri setlerine ilişkin temel istatistiksel göstergeler sunulmuştur.




Şekil 5.1 Çalışma alanına ait yer bulduru haritası.



Şekil 5.2 Saatlik güneş ışıınımlı verileri.



Şekil 5.3 Saatlik ortalama hava sıcaklığı verileri.



Şekil 5.4 Saatlik bağıl nem verileri.

Çizelge 5.1 Işınım, sıcaklık ve bağıl nem değişkenlerinin istatistiksel göstergeleri.

Gösterge	G (W/m ²)	T (°C)	H (%)
Ortalama	197.15	12.76	59.96
Mod	0	0	63.00
Medyan	3.40	12.50	63.00
Maksimum	1117.30	36.90	98.50
Minimum	0	-15.40	11.00
Standart Sapma	288.88	9.05	19.2804
Skewness	1.3462	0.0687	-0.3677
Kurtosis	3.5541	2.3152	2.2823
Jarque-Bera Test İstatistiği	11039.43	712.70	1542.62
Jarque-Bera Kritik Değeri	5.99	5.85	6.26
Jarque-Bera Test Sonucu	Red	Red	Red

Çizelge 5.1’de sunulan göstergelerden biri olan mod, bir veri setinde en sık tekrar eden değeri ifade etmektedir. Bu bağlamda, tez çalışmasında kullanılan veri setleri için hesaplanan mod değerleri; G değişkeni için 0 W/m², T değişkeni için 0 °C ve H değişkeni için %63 olarak belirlenmiştir. Bir diğer temel istatistiksel ölçüt olan medyan, veri

setindeki ortanca değeri temsil etmektedir. Çalışmada hesaplanan medyan değerleri; G için 2.2 W/m^2 , T için $15.1 \text{ }^\circ\text{C}$ ve H için %57 olarak tespit edilmiştir. Minimum ve maksimum değerler ise veri setlerinin genliğini belirlemektedir. Bir diğer temel istatistiksel ölçüt olan medyan, veri setindeki ortanca değeri temsil etmektedir. Çalışmada hesaplanan medyan değerleri; G için 3.40 W/m^2 , T için $12.50 \text{ }^\circ\text{C}$ ve H için %63 olarak tespit edilmiştir. Minimum ve maksimum değerler ise veri setlerinin genliğini belirlemektedir. Kullanılan veri setlerine ilişkin yapılan analizler doğrultusunda, G değişkeninin oldukça geniş bir aralığa sahip olduğu görülmektedir ($0-1117.30 \text{ W/m}^2$). Benzer şekilde, T değişkeni -15.40 ile $36.90 \text{ }^\circ\text{C}$ arasında değişmekte, H değişkeni ise %11 ile %98.50 arasında bir dağılım sergilemektedir.

Skewness (eğiklik), bir veri setinin simetri durumunu açıklayan bir ölçüttür (Groeneveld ve Meeden 1984). G için 1.3462 değerindeki pozitif skewness, veri setinin uzun bir sağ kuyruğa sahip olduğunu ve bazı aşırı değerlerin ortalamayı yükselttiğini göstermektedir. T değişkeni için skewness değeri 0.0687 olup, T değişkeninin değişimleri simetrik bir dağılıma sergilemektedir. H değişkeni için -0.3677 olan negatif skewness değeri ise hafif bir sol eğikliğe işaret etmektedir. Kurtosis, bir dağılımın sivrililiğini ve aşırı değer yoğunluğunu ifade eder (DeCarlo 1997). G için kurtosis 3.5541 olup normal dağılıma göre biraz daha sivri bir dağılım yapısına sahiptir. T ve H değişkenleri için kurtosis değerleri ise sırasıyla 2.3152 ve 2.2823 'dir. Bu değerler, T ve H değişkenlerinin normal dağılımdan daha basık bir yapı sergilediklerine işaret etmektedir.

Jarque-Bera (JB) testi, bir veri setinin normal dağılıma uyup uymadığını belirlemek için kullanılan bir istatistiksel testtir. Skewness ve kurtosis ölçütlerini esas alarak normal dağılımdan sapmaları değerlendirir (Jarque ve Bera 1980). Bu test, özellikle küçük ve orta büyüklükteki örneklem için oldukça kullanışlıdır (Gujarati ve Porter 2009). JB testinin değeri Denklem 5.1 kullanılarak hesaplanmaktadır:

$$JB = \frac{n}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \quad (5.1)$$

Burada; JB test istatistiği değerini, n örneklem büyüklüğünü, S çarpıklık (skewness) katsayısını ve K basıklık (kurtosis) katsayısını temsil etmektedir.

JB testinin hipotezleri ise şu şekildedir:

- Null Hipotezi (H_0): Veri seti normal dağılıma sahiptir.
- Alternatif Hipotez (H_1): Veri seti normal dağılıma sahip değildir.

JB test istatistiğine karşılık gelen p-değeri, ki-kare dağılımına göre hesaplanır ve şu yorum yapılır:


- p-değeri < 0.05 ise H_0 reddedilir, veri seti normal dağılmamaktadır.
- p-değeri ≥ 0.05 ise H_0 kabul edilir, veri seti normal dağılıma uygundur.

JB testi sonucunda elde edilen test istatistikleri ve p-değerleri incelendiğinde, tüm değişkenlerin normal dağılıma uygunluk göstermediği belirlenmiştir. Özellikle G değişkeni, yüksek pozitif çarpıklık (1.3462) ve normal dağılıma kıyasla daha sivri bir dağılıma işaret eden basıklık değeri nedeniyle normal dağılım varsayımını önemli ölçüde ihlal etmektedir. Burada, tüm değişkenler için elde edilen JB test istatistikleri kritik değerin üzerindedir ve değişkenlerin normal dağılım göstermediği sonucu ortaya çıkmıştır. Tüm değişkenler için JB test istatistiklerinin kritik değerin üzerinde çıkması, parametrik modellerin doğrudan uygulanmasının uygun olmayabileceğine işaret etmektedir. Bu nedenle, verilerin DWT gibi bir teknikle ayrıştırılması, yalnızca trend ve gürültü bileşenlerini ayırmakla kalmamış, aynı zamanda normal dağılıma daha yakın yapılar elde edilmesini sağlayarak parametrik yöntemler olan MRR ve MLR'ın uygulanabilirliğini güçlendirmiştir.

Tezde kullanılan analiz kapsamında, ABİ'nin bulunduğu konum için bir yıllık saatlik ER değerlerini gösteren grafik Şekil 5.5'de sunulmuştur. Grafik, yıl boyunca saatlik ER'nin değişimini ve yerel koşullara bağlı olarak ortaya çıkan mevsimsel farklılıkları göstermektedir. Ayrıca, Çizelge 5.2'de bir yıllık saatlik ER değerlerine ilişkin temel istatistiksel göstergeler sunulmuştur.

ER değişkeni için hesaplanan istatistiksel göstergeler incelendiğinde (Çizelge 5.2), ortalama değerin 275.53 W/m^2 olduğu görülmektedir. Medyan ve mod değerlerinin 0 olması, veri setinde sıfır değerinin çok sık tekrar ettiğini ve gece saatlerinde güneş

ışınımının tamamen kesildiğini göstermektedir. Skewness değeri 0.8512 olup veri setinin sağa çarpık olduğunu, yani bazı aşırı büyük değerlerin dağılımın dengesini etkilediğini işaret etmektedir. Kurtosis değeri 2.2432 olup normal dağılımdan daha basık bir yapı göstermektedir. JB test istatistiği 1266.90 olarak hesaplanmış ve kritik değer olan 5.97'nin üzerinde bulunmuştur. Bu sonuç, ER değişkeninin normal dağılım varsayımını sağlamadığını göstermektedir. Bu durum, güneş ışıının doğası gereği belirli saatlerde yüksek değerler alması ve gece saatlerinde tamamen sıfıra düşmesi ile açıklanabilir.




Şekil 5.5 ABİ konumuna ait bir yıllık ER değerleri.

Çizelge 5.2 Dünya dışı ışıının (ER) parametresine ilişkin istatistiksel göstergeler.

Gösterge	ER (W/m ²)
Ortalama	275.53
Medyan	0
Maksimum	1323.75
Minimum	0
Standart Sapma	345.80
Skewness	0.8512
Kurtosis	2.2432
Jarque-Bera Test İstatistiği	1266.90
Jarque-Bera Kritik Değeri	5.97
Jarque-Bera Test Sonucu	Red

Tezde kullanılan dört yıllık saatlik CI değerlerinin dağılımını gösterir grafik Şekil 5.6’da ve genel istatistiksel göstergeleri ise Çizelge 5.3’te verilmiştir.



Şekil 5.6 Saatlik CI değerleri.

Çizelge 5.3 Açıklık endeksi (CI) parametresine ilişkin istatistiksel göstergeler (sadece güneşli saatler için).

Gösterge	K_t
Ortalama	0.6435
Mod	0.006
Medyan	0.7224
Maksimum	0.94
Minimum	0.006
Standart Sapma	0.3939
Skewness	-0.4493
Kurtosis	1.7415
Jarque-Bera Test İstatistiği	1581.78
Jarque-Bera Kritik Değeri	5.99
Jarque-Bera Test Sonucu	Red

İstatistiksel analiz sonuçlarına göre, CI değerlerinin ortalaması 0.6435 ve medyanı 0.7224 olarak elde edilmiştir. Bu merkezi eğilim ölçütleri, analiz edilen saatlerde atmosferik şeffaflığın genel olarak yüksek olduğunu ve güneş ışınımının yer yüzeyine

ulaşmasında önemli bir engelin bulunmadığını göstermiştir. Özellikle mod değerinin 1 olması, açık gökyüzü koşullarının analiz edilen saatler arasında baskın olduğunu ortaya koymuştur. Standart sapmanın 0.3439 gibi orta düzeyde bir değere sahip olması, CI değerlerinin tamamen sabit olmadığını, zaman zaman yarı açık atmosferik koşulların da gözlemlendiğini göstermiştir. Bu durum, bölgedeki meteorolojik koşulların belli ölçüde değişkenlik gösterdiğini ima etmiştir.

Skewness (çarpıklık) değerinin -0.4493 olması, dağılımın sola çarpık olduğunu, yani veri setinde yüksek CI değerlerinin çoğunlukta olduğunu, ancak zaman zaman daha düşük CI değerlerinin de gözlemlendiğini ifade etmektedir. Bu bulgu, güneşli saatlerde dahi atmosferik şeffaflığın tam olmadığı bazı anların varlığına işaret etmektedir. Kurtosis değerinin 1.7415 ile normal dağılıma kıyasla daha yayvan bir dağılımı göstermesi, CI değerlerinin uç noktalarda toplanmadığını, bunun yerine daha dengeli bir dağılım sergilediğini ortaya koymaktadır. Jarque-Bera testi sonucunda elde edilen test istatistiği (1581.78), kritik değerin (5.99) oldukça üzerinde olup sıfır hipotezinin reddine neden olmuştur. Bu da CI dağılımının normal dağılımdan anlamlı derecede sapma gösterdiğini, simetrik olmadığını ve istatistiksel olarak farklı bir yapıya sahip olduğunu göstermektedir. Sonuç olarak, yalnızca güneşli saatler analiz edildiğinde, elde edilen bulgular Afyonkarahisar'ın güneşlenme potansiyelinin yüksek olduğunu ortaya koymaktadır. Bu durum, bölgenin çoğunlukla açık veya az bulutlu hava koşullarına sahip olduğunu ve literatürde bilinen güneşlenme özellikleriyle örtüştüğünü göstermektedir.

5.2 Tüm Veri Setlerinin ve Açıklık Endeksi Değerlerinin Ayrıştırılması

Belirlenen WRBA ve CA-WRBA tahmin stratejileri kapsamında; saatlik formattaki güneş ışıınımı, ortalama hava sıcaklığı ve bağıl nem değişkenleri, tek boyutlu DWT yöntemi kullanılarak birinci, ikinci, üçüncü ve dördüncü seviyelerde ayrıştırılmıştır. Saatlik CI değerleri ise tek boyutlu DWT yöntemi kullanılarak sadece birinci seviyede ayrıştırılmıştır. Ayrıştırma sürecinde, tüm veri setlerinin genel dalga şekillerinin benzerlik gösterdiği düşünülen db10 dalgacığı tercih edilmiştir. Bu tercih ile hem tüm veriler için ortak ve tutarlı bir dalgacık deseni belirlenmiş hem de her bir değişkenin karakteristik özelliklerinin maksimum düzeyde temsil edilmesi hedeflenmiştir.

Farklı seviyelerde DWT ayrıştırmaları yapılması sayesinde ise her bir verinin içerdiği düşük ve yüksek frekans bileşenleri ayrıntılı şekilde analiz edilmiştir. Bu sayede, hem kısa vadeli dalgalanmaların hem de uzun vadeli eğilimlerin daha doğru şekilde modellenmesi amaçlanmıştır. Farklı seviyelerde elde edilen bileşenlerin model performansı üzerindeki etkisi karşılaştırmalı olarak değerlendirilmiş ve bu doğrultuda tahmin doğruluğunu en üst düzeye çıkaran en uygun ayrıştırma seviyesi belirlenmeye çalışılmıştır. Böylece, yalnızca verinin yapısal özellikleriyle uyumlu bir temsil elde edilmekle kalınmamış, aynı zamanda tahmin modellerinin girişleri açısından en uygun ayrıştırma yapısı belirlenmiş ve gelecekte tek boyutlu DWT ayrıştırma tekniğini kullanacaklar için de genel bir projeksiyon çizilmiştir.


Yöntemsel olarak DWT, bir zaman serisini farklı frekans bileşenlerine ayırarak hem düşük hem de yüksek frekanslı bilgileri yakalamaya olanak tanıyan güçlü bir sinyal işleme tekniğidir. Bu kapsamda, her seviyede elde edilen detay (D_n) ve yaklaşık (A_n) sinyaller, zaman serisinin farklı çözünürlüklerdeki temsilini sunar. Yani, bir sinyalin çok ölçekli temsili, ardışık olarak ayrıştırılmış bu bileşenlerin toplamından yeniden inşa edilebilir. Matematiksel olarak, dördüncü seviyede tek boyutlu DWT ile ayrıştırılmış bir sinyal (S) Denklem 5.2'deki şekilde ifade edilebilir:

$$S(t) = A_4(t) + D_4(t) + D_3(t) + D_2(t) + D_1(t) \quad (5.2)$$


Burada;

- $A_4(t)$, dördüncü seviyedeki yaklaşık bileşeni temsil eder.
- $D_n(t)$ ($n = 1,2,3,4$), her seviyedeki detay bileşenlerini ifade eder.


Tahmin yaklaşımlarında kullanılan tüm değişkenlerin tüm seviyelerdeki ayrıştırmaları sonucu elde edilen tüm A_n ve D_n 'lerin grafikleri Şekil 5.7-5.14'te verilmiştir. Grafiklerde, G değişkeni ışıınımı, T değişkeni ortalama hava sıcaklığını, H değişkeni yüzde bağıl nemi ve CI değişkeni ise saatlik CI değerlerini temsil etmektedir.




Şekil 5.7 Birinci seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.




Şekil 5.8 Birinci seviye ayrıştırma sonucu elde edilen detay sinyalleri.




Şekil 5.9 İkinci seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.




Şekil 5.10 İkinci seviye ayrıştırma sonucu elde edilen detay sinyalleri.




Şekil 5.11 Üçüncü seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.



Şekil 5.12 Üçüncü seviye ayrıştırma sonucu elde edilen detay sinyalleri.



Şekil 5.13 Dördüncü seviye ayrıştırma sonucu elde edilen yaklaşık sinyalleri.



Şekil 5.14 Dördüncü seviye ayrıştırma sonucu elde edilen detay sinyalleri.

Grafiklerden de görülebileceği üzere, ayrıştırma seviyesi arttıkça yaklaşık sinyallerinin daha düşük frekanslı bileşenleri temsil ettiği ve sinyalin genel eğilimlerini daha belirgin

şekilde yansıttığı net bir şekilde görülmektedir. Yüksek frekanslı değişimlerin bastırılması sonucunda, ayrıştırma seviyesi arttıkça yaklaşık sinyalleri zaman içinde daha düzgün ve yumuşak bir yapı kazanmaktadır. Detay sinyallerine bakıldığında ise, ayrıştırma seviyesi yükseldikçe temsil ettikleri frekans bantlarının daraldığı ve yakalanan hızlı ve ani değişimlerin daha düşük frekanslı dalgalanmalara kaydığı gözlemlenmektedir. Üst seviyelerde, detay sinyaller daha geniş zaman ölçeklerindeki dalgalanmaları yansıtarak sinyalin orta ve düşük frekanslı geçici özelliklerini ortaya çıkarmaktadır.

5.3 Çok Değişkenli Ridge ve Lasso Regresyon Modellerinin Belirlenmesi

WRBA ve CA-WRBA kapsamında kullanılacak alt sinyallerin belirlenmesinin ardından tüm yaklaşımlar kapsamında altı aylık ve bir yıllık test dönemleri için oluşturulacak ışıınım tahmin modelleri MRR ve MLR yöntemleri ile belirlenmiştir.

BRBA yaklaşımı kapsamında V1, V2 ve V3 giriş versiyonları için MRR ve MLR modellerinin katsayıları olan β_0 , β_1 , β_2 ve β_3 değerleri belirlenmiştir. MRR ve MLR yöntemleriyle tüm giriş seti versiyonları için belirlenen bu katsayılar üç buçuk yıllık ve üç yıllık eğitim dönemleri için sırasıyla Çizelge 5.4 ve Çizelge 5.5'te verilmiştir. Çizelge 5.4 ve Çizelge 5.5'te verilen β_0 değerleri tüm modeller için sabit terimlerdir. β_1 değerleri tüm modeller için ışıınım değerlerinin katsayılarıdır. β_2 değerleri; V1 için ortalama hava sıcaklığı değerlerinin katsayısı, V2 için ise yüzde bağıl nem değerlerinin katsayılarıdır. V3'te ise β_2 sıcaklık katsayıları, β_3 değerleri ise bağıl nem değerlerinin katsayısıdır.

Çizelge 5.4 BRBA için tüm versiyonların model katsayıları (üç buçuk yıllık eğitim dönemi için).

Yöntem	Versiyon	β_0	β_1	β_2	β_3
MRR	V1	37.7326	0.9564	-2.3430	-
	V2	-122.4412	0.9872	2.0701	-
	V3	-157.9910	0.9833	1.1152	2.4416
MLR	V1	38.9563	0.9562	-2.3384	-
	V2	-120.4521	0.9870	2.0676	-
	V3	-153.8650	0.9832	1.1032	2.4351

Çizelge 5.5 BRBA için tüm versiyonların model katsayıları (üç yıllık eğitim dönemi için).

Yöntem	Versiyon	β_0	β_1	β_2	β_3
MRR	V1	38.5460	0.9593	-2.3740	-
	V2	-123.5735	0.9886	2.0789	-
	V3	-167.3785	0.9850	1.3060	2.5346
MLR	V1	39.7850	0.9591	-2.3694	-
	V2	-120.3535	0.9884	2.0761	-
	V3	-163.8620	0.9848	1.3042	2.5244

Çizelge 5.4 ve 5.5 incelendiğinde, MRR ve MLR yöntemlerinin V1 versiyonları için oluşturulan model parametreleri karşılaştırıldığında, her iki yöntemde de β_0 ve β_1 katsayıları birbirine oldukça yakın olup, β_2 katsayısının negatif işareti, ikinci bağımsız değişken olan ortalama hava sıcaklığı değişkeninin ısıtım tahmini üzerindeki ters yönlü etkisine işaret etmiştir. V2 versiyonunda ise hem MRR hem de MLR yöntemleriyle oluşturulan modellerde β_0 katsayısının negatif ve mutlak değerce yüksek olduğu dikkat çekmiştir. Bu durum, modelin sabit bileşeninin veri yapısında belirgin bir kayma veya baz etkisine işaret ettiğini düşündürmüştür. β_1 ve β_2 katsayılarının pozitif değerler alması, ilgili bağımsız değişkenlerin tahmin gücünün V2 giriş seti versiyonunda pozitif yönde çalıştığını göstermiştir. V3'te β_0 katsayısının negatifliği ve mutlak değerinin yüksekliği, bu versiyonda daha güçlü bir baz etkisinin varlığına işaret etmiştir. Ayrıca, β_2 ve β_3 katsayılarının birbirine yakın olması, bu iki bağımsız değişkenin model üzerindeki etkilerinin benzer büyüklükte olduğunu ve modelde ağırlık açısından daha dengeli bir dağılımın sağlanmış olabileceğini düşündürmüştür. Ayrıca, belirlenen tüm modeller için bir saat öncesinin ısıtım değerinin katsayısı olan β_1 katsayısı tüm modellerde doğal olarak oldukça yüksek değerler almıştır.

WRBA ve CA-WRBA kapsamında, tüm giriş seti versiyonları için üç buçuk yıllık ve üç yıllık eğitim dönemleri kullanılarak, DWT-MRR ve DWT-MLR modellerinin katsayıları belirlenmiştir. Birinci seviyeden dördüncü seviyeye kadar yapılan ayrıştırmalar sonucunda elde edilen alt sinyaller için belirlenen β_0 , β_1 , β_2 ve β_3 katsayıları, BRBA'da kullanılan biçimiyle tüm versiyonlar için sabit tutulmuştur. Üç buçuk yıllık eğitim verileri kullanılarak oluşturulan DWT-MRR modeli katsayıları Çizelge 5.6'da, DWT-MLR

modeli katsayıları ise Çizelge 5.7’de sunulmuştur. Üç yıllık eğitim verileriyle oluşturulan DWT-MRR ve DWT-MLR model sonuçları ise sırasıyla Çizelge 5.8 ve Çizelge 5.9’da sunulmuştur.

Çizelge 5.6 WRBA ve CA-WRBA için DWT-MRR modelleri katsayıları (üç buçuk yıllık eğitim dönemi için).

VX	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
V1	1	37.010	0.980	-2.659	-	-3.6×10^{-4}	-0.566	-13.150	-
	2	8.576	0.954	0.035	-	0.002	0.451	-0.033	-
	3	5.360	0.971	0.029	-	-0.002	0.858	-0.063	-
	4	0.277	0.998	-9×10^{-4}	-	-0.010	0.966	0.361	-
V2	1	12.263	0.944	-0.020	-	-3.5×10^{-4}	-0.566	-0.015	-
	2	10.573	0.954	-0.026	-	0.002	0.451	0.064	-
	3	7.037	0.971	-0.022	-	-0.002	0.858	-0.015	-
	4	0.267	0.999	3.6×10^{-4}	-	-0.010	0.966	-0.159	-
V3	1	38.744	0.980	-2.660	-0.029	-3.6×10^{-4}	-0.566	-13.150	-0.006
	2	11.169	0.954	-0.016	-0.032	0.002	0.451	0.160	0.093
	3	7.757	0.971	-0.019	-0.030	-0.002	0.858	-0.118	-0.036
	4	0.590	0.949	-0.018	-0.031	-0.010	0.966	0.090	0.0460

Tüm ayrıştırma seviyelerindeki DWT-MRR ve DWT-MLR modellerine ait katsayıların ayrıntılı incelenmesi, yaklaşık sinyallerine (A_n) ait β_0 katsayısının ayrıştırma seviyesi (n) arttıkça artarak azaldığını ortaya koymuştur. Bu azalma, ayrıştırma seviyesi yükseldikçe kullanılan bağımsız değişkenlerin bağımlı değişkeni (yani bir sonraki saatin ısıtım değeri tahminini) daha yüksek bir doğrulukla açıkladığını göstermiştir. Yine ayrıştırma seviyesi arttıkça modelin karmaşıklığının da arttığı gözlemlenmiş, bu durum ise aşırı uyum riskine karşı dikkatli olunması gerektiğine işaret etmiştir. Detay sinyallerine (D_n) ait modellerde β_0 ve β_1 katsayılarının aynı n değeri için her versiyonda birbirine oldukça yakın olduğu tespit edilmiştir. Bu bulgu, ısıtım değişkeninin detay sinyallerinin tahminleri üzerinde diğer model değişkenlerinden bağımsız olarak anlamlı bir etkiye sahip olduğunu ve diğer parametrelerin katsayılarındaki değişimlerden büyük ölçüde etkilenmediğini ortaya

koymuştur. Ayrıca, eğitim verisi sayısı arttıkça yaklaşık sinyallerinin β_1 katsayılarında bir kısım azalma gözlemlenmiştir. Bunun sebebi, daha uzun dönemli eğitim verilerinin modele daha istikrarlı ve genellenebilir ilişki kalıpları kazandırmasıdır.

Çizelge 5.7 WRBA ve CA-WRBA için DWT-MLR modelleri katsayıları (üç buçuk yıllık eğitim dönemi için).

VX	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
V1	1	37.010	0.980	-2.660	-	-3.6×10^{-4}	-0.566	-13.150	-
	2	8.624	0.954	0.035	-	0.003	0.451	-0.033	-
	3	5.497	0.971	0.029	-	-0.002	0.858	-0.062	-
	4	0.296	0.999	-9×10^{-4}	-	-0.010	0.966	0.361	-
V2	1	12.277	0.944	-0.021	-	-3.5×10^{-4}	-0.566	-0.015	-
	2	10.583	0.954	-0.026	-	0.003	0.451	0.064	-
	3	7.072	0.971	-0.022	-	-0.002	0.858	-0.015	-
	4	0.286	0.999	3.4×10^{-4}	-	-0.010	0.966	-0.159	-
V3	1	38.744	0.980	-2.661	-0.029	-3.6×10^{-4}	-0.566	-13.148	-0.006
	2	11.224	0.954	-0.016	-0.032	0.003	0.451	0.160	0.093
	3	7.912	0.971	-0.019	-0.030	-0.002	0.858	-0.118	-0.036
	4	0.715	0.948	-0.018	-0.031	-0.010	0.966	0.089	0.0460

5.4 Kümeleme Süreçleri

CA-WRBA kapsamında geliştirilen DWT-MRR ve DWT-MLR yöntemlerinin tüm giriş seti versiyonları ile oluşturulan modellerin farklı hava açıklık koşullarındaki performanslarını değerlendirmek amacıyla; manuel, k-means ve kernel k-means algoritmaları kullanılarak üç farklı bulutluluk durumu için CI değerleri için kümeler oluşturulmuştur. CI değerlerini içeren veri kümesinin eğitim verileri (ilk üç yıl ve üç buçuk yıl) manuel, k-means ve kernel k-means algoritmaları kullanılarak kümeleme işlemlerine tabi tutulmuştur. Bu üç algoritma kullanılarak, CI değerleri için MC, C ve SC saatler olarak kategorize edilen üç farklı bulutluluk kümesi oluşturulmuştur.

Çizelge 5.8 WRBA ve CA-WRBA için DWT-MRR modelleri katsayıları (üç yıllık eğitim dönemi için).

VX	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
V1	1	38.078	0.977	-2.692	-	-2.7×10^{-4}	-0.561	-13.158	-
	2	9.150	0.950	0.032	-	0.002	0.449	-0.032	-
	3	6.080	0.969	0.028	-	-0.002	0.860	-0.061	-
	4	0.350	0.997	-8.7×10^{-4}	-	-0.015	0.970	0.358	-
V2	1	11.851	0.942	-0.017	-	-2.5×10^{-4}	-0.560	-0.020	-
	2	11.732	0.946	-0.028	-	0.002	0.463	0.066	-
	3	7.858	0.970	-0.020	-	-0.002	0.862	-0.013	-
	4	0.267	0.997	2.9×10^{-4}	-	-0.010	0.970	-0.156	-
V3	1	39.914	0.978	-2.693	-0.031	-2.7×10^{-4}	-0.562	-13.155	-0.007
	2	12.320	0.948	-0.017	-0.033	0.002	0.452	0.162	0.096
	3	7.963	0.969	-0.018	-0.029	-0.002	0.861	-0.116	-0.034
	4	0.651	0.945	-0.016	-0.028	-0.010	0.972	0.089	0.0456

Kullanılan ilk algoritmik yaklaşım olan manuel yöntem, herhangi bir hesaplama yükü gerektirmeyen ve tamamen öznel yargılara dayanan bir tekniktir. Kümeleme için kullanılan ikinci algoritma ise k-means algoritmasıdır. Bu algoritmanın ilk aşamasında, veriler üç ana gruba ayrılmış ve her grup için ortalama CI değeri belirlenmiştir. Daha sonra k-means algoritması ile Denklem 3.12 minimize edilene kadar Denklem 3.13 ve 3.14'te özetlenen adımları tekrarlayarak üç küme için sınır değerleri elde edilmiştir. Saatlik CI değerlerini kümelemek için kullanılan üçüncü algoritma ise kernel k-means algoritmasıdır. Verileri doğrudan uzayda kümeleyen klasik k-means algoritmasının aksine, kernel k-means algoritması bir kernel matrisine dayalı bir uzayda kümelemeye izin verir. Bu, doğrusal olmayan kümelerin daha etkili bir şekilde belirlenmesini kolaylaştırır. Kernel k-means algoritmasında kernel matrisi olarak radyal tabanlı fonksiyon (RBF) seçilmiştir. RBF çekirdek fonksiyonu, Gauss fonksiyonunda bir temeli olan iki veri noktası arasındaki benzerlik derecesini ölçmek için kullanılır. RBF çekirdek matrisi, RBF çekirdek fonksiyonunu kullanarak bir veri kümesindeki tüm örnekler arasındaki benzerlikleri hesaplayan bir matristir. Bu seçim temel olarak CI veri setinin

doğrusal olmayan yapısından kaynaklanmıştır. RBF çekirdeği, özellikle Gauss çekirdek fonksiyonu olarak bilinen formda yaygın olarak kullanılır. RBF formülü Denklem 5.2’de verilmiştir. Bu formül arasındaki benzerliği şu şekilde tanımlar (Singh 2024):

$$K(x, x') = e^{\left(\frac{\|x-x'\|^2}{2\sigma^2}\right)} \quad (5.2)$$

Burada; $\|x - x'\|^2$ iki örnek arasındaki öklidyen mesafenin karesine, σ Gauss fonksiyonunun standart sapması olan yayılım parametresine ve $\gamma = \frac{1}{2\sigma^2}$ ise kernelin yayılımını kontrol eden parametreye karşılık gelmektedir. Bu fonksiyon, uzaklık arttıkça benzerliğin üssel olarak azaldığı anlamını taşır. Bu da kernel k-means gibi algoritmalarda doğrusal olmayan sınırlara duyarlılığı artırır.

Çizelge 5.9 WRBA ve CA-WRBA için DWT-MLR modelleri katsayıları (üç buçuk yıllık eğitim dönemi için).

VX	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
V1	1	39.123	0.979	-2.660	-	-2.9x10 ⁻⁴	-0.563	-13.159	-
	2	9.356	0.952	0.031	-	0.002	0.451	-0.031	-
	3	6.291	0.967	0.026	-	-0.002	0.863	-0.058	-
	4	0.626	0.998	-7.9x10 ⁻⁴	-	-0.015	0.973	0.356	-
V2	1	12.520	0.942	-0.016	-	-3.3x10 ⁻⁴	-0.562	-0.019	-
	2	11.260	0.950	-0.025	-	0.002	0.466	0.064	-
	3	8.253	0.970	-0.018	-	-0.002	0.865	-0.011	-
	4	0.334	0.998	3x10 ⁻⁴	-	-0.010	0.973	-0.155	-
V3	1	41.028	0.978	-2.686	-0.029	-2.8x10 ⁻⁴	-0.560	-13.153	-0.068
	2	14.264	0.951	-0.016	-0.032	0.002	0.455	0.160	0.095
	3	8.752	0.970	-0.015	-0.027	-0.002	0.865	-0.115	-0.033
	4	0.825	0.946	-0.014	-0.025	-0.010	0.974	0.088	0.045

Kümelerin sınırları belirlendikten sonra, en başarılı algoritmanın tespiti amacıyla silhouette skoru (SS) değerine başvurulmuştur. Bu SS değeri, farklı kümeleme

algoritmalarının başarı düzeylerinin karşılaştırılması noktasında yaygın olarak kullanılmaktadır. SS değeri Denklem 5.3, ortalama SS değeri ise Denklem 5.4 kullanılarak hesaplanmaktadır:

$$s(i) = \frac{b(i)-a(i)}{\max(a(i),b(i))} \quad (5.3)$$

$$\bar{s} = \frac{1}{n} \sum_{i=1}^n s(i) \quad (5.4)$$

Burada; $s(i)$, i. veri noktasının SS değeri, $a(i)$, i. veri noktasının kendi kümesindeki diğer veri noktalarına olan ortalama uzaklığı ve $b(i)$, i. veri noktasının en yakın kümedeki veri noktalarına olan ortalama uzaklığıdır. $\bar{s}$ ise tüm SS değerlerinin ortalamasıdır.

SS, her bir gözlemin ait olduğu kümeye ne kadar uygun ve diğer kümelerden ne kadar ayrıık olduğunu değerlendirerek, kümelenme kalitesine dair nicel bir ölçüt sunmaktadır. Skor değeri -1 ile 1 arasında değişmekte olup, bu değerin yüksek olması, veri noktalarının uygun kümelere atanmış olduğunu göstermektedir. Ortalama SS değerinin en yüksek olduğu algoritma, genellikle en uygun kümeleme yöntemi olarak kabul edilmektedir (Ogbuabor ve Ugwoke 2018). Tüm algoritmalar ile kümelerin sınırları belirlenmiştir. Çizelge 5.10’da üç buçuk, Çizelge 5.11’de ise üç yıllık eğitim dönemleri kullanılarak üç algoritma ile belirlenen sınır değerleri ile ortalama SS değerleri sunulmuştur.

Çizelge 5.10 Oluşturulan CI kümelerinin sınırları (üç buçuk yıllık eğitim dönemi için).


Kümeleme Algoritması	Çok Bulutlu Küme (MC)	Bulutlu Küme (C)	Az Bulutlu Küme (SC)	Ortalama SS Değeri
Manuel	$0 \leq CI \leq 0.3500$	$0.3500 < CI \leq 0.7000$	$0.7000 < CI \leq 1$	0.7411
K-Means	$0 \leq CI \leq 0.3541$	$0.3541 < CI \leq 0.6683$	$0.6683 < CI \leq 1$	0.7524
Kernel K-Means	$0 \leq CI \leq 0.3053$	$0.3053 < CI \leq 0.6518$	$0.6518 < CI \leq 1$	0.7769

Çizelge 5.10 ve Çizelge 5.11’de sunulan ortalama SS değerleri karşılaştırıldığında, iki çizelge arasında belirgin bir fark olmadığı görülmektedir. Her iki veri seti üzerinde de benzer sonuçlar elde edilmiş olup, bu değerlere dayanarak CI verilerini en başarılı şekilde kümeleyen algoritmanın kernel k-means algoritması olduğu belirlenmiştir. Ayrıca, üç buçuk yıllık eğitim dönemi için manuel, k-means ve kernel k-means algoritmaları ile CI değerlerinin kümelenmesine ilişkin SS değerleri sırasıyla Şekil 5.15, Şekil 5.16 ve Şekil 5.17’de görselleştirilmiştir. Şekillerde, her bir veri noktasının SS değeri ve kümelendikleri gruba ne kadar uygun oldukları gösterilirken, kümeleme algoritmasının genel performans düzeyini yansıtmak amacıyla ortalama SS değerleri de kırmızı kesik çizgi ile belirtilmiştir. Yine şekillerdeki 1 rakamı MC kümesine, 2 rakamı C kümesine ve 3 rakamı ise SC kümesine karşılık gelmektedir.


Çizelge 5.11 Oluşturulan CI kümelerinin sınırları (üç yıllık eğitim dönemi için).

Kümeleme Algoritması	Çok Bulutlu Küme (MC)	Bulutlu Küme (C)	Az Bulutlu Küme (SC)	Ortalama SS Değeri
Manuel	$0 \leq CI \leq 0.3500$	$0.3500 < CI \leq 0.7000$	$0.7000 < CI \leq 1$	0.7402
K-Means	$0 \leq CI \leq 0.3549$	$0.3550 < CI \leq 0.6696$	$0.6697 < CI \leq 1$	0.7515
Kernel Means	$0 \leq CI \leq 0.3125$	$0.3126 < CI \leq 0.6520$	$0.6521 < CI \leq 1$	0.7756


Şekiller (5.15, 5.16 ve 5.17) incelendiğinde, manuel yöntem ve klasik k-means algoritması ile gerçekleştirilen kümeleme işlemlerinde, özellikle C kümesine ait bazı CI değerlerinin negatif SS değerleri aldığı gözlemlenmiştir. Bu durum, söz konusu veri noktalarının bulundukları kümelerle yeterince iyi uyum sağlayamadığını ve diğer kümelerle daha yakın olabileceklerini göstermiştir. Buna karşılık, kernel k-means algoritması ile gerçekleştirilen kümeleme sonucunda, tüm CI değerlerinin pozitif SS değerleri aldığı ve dolayısıyla kümelenmenin daha tutarlı ve gerçeğe yakın bir yapıda gerçekleştiği tespit edilmiştir. Bu bulgular, kernel k-means algoritmasının, diğer yöntemlere kıyasla daha başarılı bir kümeleme performansı sergilediğini desteklemiştir.



Şekil 5.15 Manuel yöntem ile elde edilen SS değerleri.



Şekil 5.16 K-means algoritması ile elde SS değerleri.



Şekil 5.17 Kernel k-means algoritması ile elde SS değerleri.

5.5 Nihai Tahmin Sonuçları

Bu bölümde geliştirilen tüm yaklaşımlar (BRBA, WRBA ve CA-WRBA) ile elde edilen nihai tahmin sonuçları ve bu sonuçların yorumları verilmiştir.

5.5.1 Temel Regresyon Tabanlı Yaklaşım ile Elde Edilen Tahmin Sonuçları

Her bir giriş seti versiyonu (V1, V2 ve V3) kullanılarak oluşturulan MRR ve MLR modelleri için, en düşük AIC değerine sahip modellerin daha yüksek tahmin başarısı göstereceği düşünülmüştür. Bu düşünce temelinde, AIC kriterinin model seçimi sürecinde model karmaşıklığı ile veri uyumu arasında denge kurma yetisi bulunmaktadır. Çizelge 5.12’de, V1, V2 ve V3 veri setlerinin ilk üç buçuk yıllık değerlerini içeren eğitim setleri kullanılarak oluşturulan MRR ve MLR modellerine ait AIC değerleri sunulmuştur. Çizelge 5.13’te ise yine aynı V1, V2 ve V3 veri setlerinin ilk üç yıllık eğitim setleri temel alınarak oluşturulan MRR ve MLR modellerine ait AIC değerleri verilmiştir.

Çizelge 5.12 BRBA ile oluşturulan modellerin AIC değerleri (üç buçuk yıllık eğitim dönemi için).

Versiyon	Yöntem	AIC Değerleri
V1	MRR	9.85
	MLR	10.32
V2	MRR	12.28
	MLR	13.65
V3	MRR	17.41
	MLR	19.38

Çizelge 5.13 BRBA ile oluşturulan modellerin AIC değerleri (üç yıllık eğitim dönemi için).

Versiyon	Yöntem	AIC Değerleri
V1	MRR	10.19
	MLR	10.74
V2	MRR	12.96
	MLR	13.99
V3	MRR	18.81
	MLR	20.09

Işınım, ortalama hava sıcaklığı ve yüzdesel bağıl nem değişkenlerinin birlikte yer aldığı V3 veri setine ait modellerin daha yüksek AIC değerlerine sahip olması, modelin daha fazla sayıda giriş değişkeniyle oluşturulmasından kaynaklanmıştır. Bu durum, AIC kriteri açısından modele ek ceza yüklenmesine ve modelin uygunluğunun azalmasına neden olmuştur. Sonuç olarak, AIC değerleri esas alınarak yapılan değerlendirmede, ışıınım tahmini açısından en uygun modelin MRR-V1 modeli olduğu ön değerlendirmesi yapılmıştır. Ayrıca, Çizelge 5.12 ve 5.13 karşılaştırıldığında, eğitim veri sayısının artmasının belirlenen modellerin güvenilirliğini artırdığı gözlemlenmiştir.


BRBA kapsamında oluşturulan modellerin nihai tahmin performanslarını sayısal olarak ortaya koymak amacıyla, altı aylık ve bir yıllık test periyotlarına ilişkin elde edilen tahmin çıktıları istatistiksel metrikler kullanılarak analiz edilmiştir. Bu analiz sonuçları Çizelge 5.14'te özetlenmiştir. Çizelge 5.14'te sunulan verilere göre, tüm değerlendirme kriterleri dikkate alındığında, hem altı aylık hem de bir yıllık test dönemleri için en başarılı tahmin

çıktıları MRR-V1 modeli tarafından sağlanmıştır. İlgili modelin hata ölçütlerinde en düşük değerlere ulaşması, tahmin doğruluğunun yüksekliğini ve öngörü hatalarının minimize edildiğini ortaya koymuştur.


Çizelge 5.14 BRBA kapsamında oluşturulan tüm modellerin performansları.

Yöntem	Versiyon	Test Dönemi	RMSE	NRMSE	NMAE	%R ²
MRR	V1	Altı Ay	39.7630	0.0373	0.0274	97.86
		Bir Yıl	39.6705	0.0362	0.0227	98.05
	V2	Altı Ay	57.5668	0.0540	0.0427	96.29
		Bir Yıl	55.0174	0.0526	0.0368	96.67
	V3	Altı Ay	58.6175	0.0550	0.0436	96.27
		Bir Yıl	56.9234	0.0539	0.0376	96.55
MLR	V1	Altı Ay	41.5495	0.0390	0.0279	96.65
		Bir Yıl	40.1156	0.0368	0.0253	97.80
	V2	Altı Ay	58.2581	0.0546	0.0433	96.49
		Bir Yıl	56.7401	0.0527	0.0364	96.78
	V3	Altı Ay	61.2338	0.0574	0.0454	96.42
		Bir Yıl	62.6822	0.0558	0.0389	96.53

Çizelgedeki sonuçlar MRR yöntemi açısından değerlendirildiğinde, V1 versiyonu her iki test dönemi için en düşük RMSE, NRMSE ve NMAE değerlerine ulaşmış ve en yüksek %R² değerini sağlamıştır. Bu durum, V1'in tahmin doğruluğunun hem kısa hem de uzun vadede diğer versiyonlara kıyasla daha başarılı olduğunu ortaya koymuştur. Özellikle bir yıllık test döneminde elde edilen %R² değeri (%98.05), modelin veriye oldukça iyi uyum sağladığını göstermiştir. V2 ve V3 versiyonlarında ise hata metriklerinde artış gözlenirken, determinasyon katsayısı belirgin şekilde azalmamıştır. Bu da modelin yapısal olarak benzer performansı koruduğunu ancak tahmin doğruluğunun bir miktar zayıfladığına işaret etmiştir.



Şekil 5.18 MRR-V1 ile elde edilen altı aylık tahminlerin karşılaştırması.



Şekil 5.19 MRR-V1 ile elde edilen bir yıllık tahminlerin karşılaştırması.

Çizelgedeki sonuçlar MLR yöntemi açısından incelendiğinde ise V1 versiyonu yine en iyi performansı sergilemiştir. Özellikle bir yıllık test dönemindeki $\%R^2$ değeri ($\%97.80$) oldukça yüksek olup, modelin güçlü bir genelleme yeteneğine sahip olduğunu göstermiştir. Genel olarak, her iki yöntemde de V1 giriş veri seti versiyonları ile oluşturulan tahmin modelleri öne çıkmıştır. MRR yöntemi, özellikle V1 versiyonunda MLR'ye kıyasla daha başarılı sonuçlar üretmiştir. MRR-V1 ile gerçekleştirilen altı aylık tahmin sonuçları Şekil 5.18'de, bir yıllık tahmin sonuçları ise Şekil 5.19'da sunulmuştur.

5.5.2 Dalgacık ve Regresyon Tabanlı Yaklaşım ile Elde Edilen Tahmin Sonuçları

Oluşturulan WRBA stratejisi kapsamında ilk olarak en uygun DWT ayrıştırma seviyesi belirlenmeye çalışılmıştır. Bu bağlamda, birinciden dördüncü seviyeye kadar gerçekleştirilen ayrıştırmalar sonucunda elde edilen alt sinyaller için oluşturulan üç buçuk yıllık ve üç yıllık eğitim dönemleri kullanılarak oluşturulan tahmin modellerinin AIC değerlerine bakılmıştır. DWT-MRR ve DWT-MLR yöntemleri kullanılarak V1, V2 ve V3 giriş seti versiyonları için farklı ayrıştırma seviyelerinde yaklaşık ve detay sinyalleri için elde edilen AIC değerleri sırasıyla Çizelge 5.15 ve Çizelge 5.16'da sunulmuştur.

Her bir versiyona (V1, V2 ve V3) ayrı ayrı uygulanan farklı seviyelerde gerçekleştirilen ayrıştırmalar sonucu elde edilen DWT-MRR ve DWT-MLR modellerinden en düşük AIC değerine sahip olan seviyede gerçekleştirilecek tahmin sonuçlarının daha iyi olacağı düşünülmüştür. Ayrıca WRBA kapsamında üç buçuk yıllık eğitim seti ile geliştirilen tüm modellerin yaklaşık ve detay sinyalleri için elde edilen AIC değerlerini gösterir enterpolasyon grafikleri sırasıyla Şekil 5.20 ve Şekil 5.21'de sunulmuştur.


Çizelge 5.15, Çizelge 5.16, Şekil 5.19 ve Şekil 5.20 incelendiğinde, DWT ayrıştırma seviyesi arttıkça A_n ve D_n için AIC değerinin giderek yükseldiği gözlemlenmiştir. Böylece, AIC değerleri bir fikir vermiştir: DWT ayrıştırma seviyesinin yükselmesi, oluşturulacak güneş ışınlımı tahmin modellerinin performansını olumsuz etkileyecektir. A_n ve D_n sinyalleri için AIC değerleri incelendiğinde, optimum DWT ayrıştırma seviyesinin birinci seviye olduğu çıkarımı yapılmıştır. Çizelge 5.17'de tüm seviyelerdeki yaklaşık ve detay sinyallerinin üç buçuk yıllık eğitim setleri ile oluşturulan DWT-MRR modelleri için β_0 , β_1 , β_2 ve β_3 değerleri sunulmuştur.

Çizelge 5.15 WRBA ile oluşturulan modellerin AIC değerleri (üç buçuk yıllık eğitim dönemi için).


Ayrıştırma Seviyesi	Tahmin Yöntemi	Versiyon	A_n	D_n
1.	DWT-MRR	V1	5.2852	2.0694
		V2	5.2677	3.6915
		V3	5.2963	2.0652
	DWT-MLR	V1	5.2851	2.0756
		V2	5.2657	3.7679
		V3	5.2839	2.0691
2.	DWT-MRR	V1	6.4380	6.5221
		V2	6.4388	5.5342
		V3	7.4747	5.5350
	DWT-MLR	V1	6.4345	5.5333
		V2	6.4369	5.5354
		V3	7.4379	5.5361
3.	DWT-MRR	V1	7.3050	6.0115
		V2	7.3196	6.0890
		V3	8.9075	6.8520
	DWT-MLR	V1	7.2846	6.1646
		V2	7.2882	6.1643
		V3	8.8850	6.9822
4.	DWT-MRR	V1	13.9526	7.4090
		V2	14.0288	7.4546
		V3	15.9632	7.8865
	DWT-MLR	V1	13.6798	7.5950
		V2	13.6711	7.6281
		V3	15.5225	8.0896

Çizelge 5.16 WRBA ile oluşturulan modellerin AIC değerleri (üç yıllık eğitim dönemi için).

Ayrıştırma Seviyesi	Tahmin Yöntemi	Versiyon	A_n	D_n
1.	DWT-MRR	V1	5.3965	2.0696
		V2	5.3896	3.6950
		V3	5.4146	2.0700
	DWT-MLR	V1	5.2875	2.0756
		V2	5.2682	3.7691
		V3	5.2886	2.0702
2.	DWT-MRR	V1	6.4380	6.5252
		V2	6.4425	5.5362
		V3	7.5122	5.5367
	DWT-MLR	V1	6.4350	5.5336
		V2	6.4369	5.5354
		V3	7.4389	5.5366
3.	DWT-MRR	V1	7.3074	6.0117
		V2	7.3246	6.0895
		V3	8.9090	6.8523
	DWT-MLR	V1	7.2854	6.1648
		V2	7.2896	6.1649
		V3	8.8900	6.9826
4.	DWT-MRR	V1	13.9552	7.4095
		V2	14.1256	7.4554
		V3	15.9726	7.8870
	DWT-MLR	V1	13.6878	7.5972
		V2	13.6883	7.6292
		V3	15.7528	8.0902



Şekil 5.20 Ayrıştırma seviyeleri için modellerin AIC değerleri (yaklaşık sinyalleri için).



Şekil 5.21 Ayrıştırma seviyeleri için modellerin AIC değerleri (detay sinyalleri için).

Çizelge 5.17 DWT-MRR modellerinin β değerleri (üç buçuk yıllık eğitim dönemi için).

V	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
1	1	37.010	0.980	-2.659	-	-3.6×10^{-4}	-0.566	-13.150	-
	2	8.577	0.954	0.035	-	0.002	0.451	-0.033	-
	3	5.360	0.971	0.029	-	-0.002	0.858	-0.063	-
	4	0.278	0.999	-9×10^{-4}	-	-0.010	0.966	0.361	-
2	1	12.263	0.944	-0.020	-	-3.5×10^{-4}	-0.566	-0.015	-
	2	10.573	0.954	-0.026	-	0.002	0.451	0.064	-
	3	7.037	0.971	-0.022	-	-0.002	0.858	-0.015	-
	4	0.267	0.999	4×10^{-4}	-	-0.010	0.966	-0.159	-
3	1	38.744	0.980	-2.660	-0.029	-3.6×10^{-4}	-0.566	-13.148	-0.006
	2	11.169	0.954	-0.016	-0.032	0.002	0.451	0.160	0.093
	3	7.757	0.971	-0.019	-0.030	-0.002	0.858	-0.118	-0.036
	4	0.590	0.949	-0.018	-0.031	-0.010	0.966	0.090	0.046

Çizelge 5.18'de, tüm seviyelerdeki üç buçuk yıllık eğitim setleri ile yaklaşık ve detay sinyalleri için oluşturulan DWT-MLR modelleri için β_0 , β_1 , β_2 ve β_3 değerleri verilmiştir (λ tüm alt sinyal modelleri için 0,95'e eşittir). Üç yıllık eğitim setleri kullanılarak elde edilen β_0 , β_1 , β_2 ve β_3 katsayılarının yer aldığı tablolar ise sırasıyla Çizelge 5.19 ve Çizelge 5.20'de sunulmuştur. Tüm bu söz konusu çizelgelerdeki (5.17, 5.18, 5.19 ve 5.20) β_0 değerleri tüm modeller için sabit terimlerdir. β_1 değerleri tüm modeller için ısıtım değerlerinin katsayılarıdır. β_2 değerleri, V1 için ortalama hava sıcaklığı ve V2 için yüzde bağıl nem değerlerinin katsayılarıdır. V3 için, β_2 değerleri ortalama hava sıcaklığı değerlerinin katsayılarını verirken β_3 değerleri ise yüzde bağıl nem değerlerine ait katsayılarıdır.

Çizelgelerdeki (5.17-5.20) modellerin katsayıları detaylı bir şekilde incelendiğinde, ayrıştırma seviyesi (n) arttıkça yaklaşık sinyallerin (A_n) β_0 değerinde kayda değer bir düşüş olduğu görülmüştür. Bu düşüş, ayrıştırma seviyesi arttıkça, bağımsız değişkenlerin bağımlı değişkeni (yani bir saat sonrasının ısıtım değerinin tahminini) A_n için daha büyük

bir hassasiyetle açıkladığını göstermiştir. Ayrıca, detay sinyalleri (D_n) modellerinin β_0 ve β_1 katsayıları, her bir versiyonda aynı n değerleri için neredeyse eşittir. Bu bulgu, ışınlam değişkeninin modeldeki diğer değişkenlerden bağımsız olarak D_n tahminini önemli ölçüde etkilediğini ve diğer değişkenlerin katsayılarındaki değişikliklerden büyük ölçüde etkilenmediğini göstermiştir.

Çizelge 5.18 DWT-MLR modellerinin β değerleri (üç buçuk yıllık eğitim dönemi için).

V	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
1	1	37.010	0.980	-2.660	-	-3.6×10^{-4}	-0.566	-13.150	-
	2	8.624	0.954	0.035	-	0.003	0.451	-0.033	-
	3	5.497	0.971	0.029	-	-0.002	0.858	-0.062	-
	4	0.296	0.998	-9×10^{-4}	-	-0.010	0.966	0.361	-
2	1	12.277	0.944	-0.021	-	-3.5×10^{-4}	-0.566	-0.015	-
	2	10.583	0.954	-0.026	-	0.003	0.451	0.064	-
	3	7.072	0.971	-0.022	-	-0.002	0.858	-0.015	-
	4	0.286	0.998	3×10^{-4}	-	-0.010	0.966	-0.159	-
3	1	38.744	0.980	-2.660	-0.0290	-3.6×10^{-4}	-0.566	-13.148	-0.006
	2	11.224	0.954	-0.016	-0.0323	0.003	0.451	0.160	0.093
	3	7.912	0.971	-0.019	-0.0301	-0.002	0.858	-0.118	-0.036
	4	0.715	0.948	-0.018	-0.0315	-0.010	0.966	0.089	0.046

Alt sinyaller için model katsayılarının belirlenmesinin ardından tüm alt sinyaller için alt sinyal tahminleri altı aylık ve bir yıllık test dönemleri için gerçekleştirilmiştir. Alt sinyallerin tahminler DWT yeniden yapılandırması kullanılarak ana tahmin sinyallerine dönüştürülmüştür. Ana tahmin sinyalleri oluşturulduktan sonra, WRBA ile belirlenen tüm modellerin performanslarını incelemek için yine RMSE, NRMSE, NMAE ve $\%R^2$ değerlerine başvurulmuştur. AIC değerleri esas alınarak belirlenen optimum DWT ayrıştırma seviyesi olan birinci seviyede gerçekleştirilen ayrıştırma sonucunda elde edilen tahmin modellerinin altı aylık ve bir yıllık test dönemleri için tahmin performansına ilişkin istatistiksel sonuçlar Çizelge 5.21’de sunulmuştur.

Çizelge 5.19 DWT-MRR modellerinin β değerleri (üç yıllık eğitim dönemi için).

V	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
1	1	37.850	0.976	-2.715	-	-0.002	-0.532	-14.002	-
	2	8.653	0.952	0.040	-	0.015	0.440	-0.038	-
	3	5.932	0.968	0.033	-	-0.026	0.842	-0.075	-
	4	0.365	0.998	-0.001	-	-0.030	0.923	0.396	-
2	1	13.590	0.939	-0.023	-	-0.001	-0.545	-0.020	-
	2	11.964	0.950	-0.029	-	0.013	0.428	0.076	-
	3	7.846	0.965	-0.026	-	-0.010	0.802	-0.028	-
	4	0.423	0.997	0.001	-	-0.026	0.941	-0.178	-
3	1	40.010	0.974	-2.802	-0.029	-0.001	-0.535	-14.152	-0.009
	2	13.005	0.950	-0.018	-0.032	0.010	0.445	0.175	0.096
	3	9.102	0.961	-0.021	-0.030	-0.015	0.843	-0.128	-0.041
	4	0.750	0.942	-0.025	-0.031	-0.026	0.928	0.103	0.053

Çizelge 5.20 DWT-MLR modellerinin β değerleri (üç buçuk yıllık eğitim dönemi için).

V	n	A_n				D_n			
		β_0	β_1	β_2	β_3	β_0	β_1	β_2	β_3
1	1	37.965	0.975	-2.717	-	-0.002	-0.532	-14.002	-
	2	8.724	0.952	0.041	-	0.017	0.440	-0.039	-
	3	6.354	0.967	0.034	-	-0.028	0.842	-0.076	-
	4	0.385	0.996	-0.001	-	-0.033	0.923	0.398	-
2	1	13.653	0.938	-0.024	-	-0.001	-0.545	-0.020	-
	2	12.251	0.948	-0.030	-	0.015	0.428	0.078	-
	3	7.937	0.962	-0.028	-	-0.013	0.802	-0.029	-
	4	0.605	0.995	0.001	-	-0.028	0.941	-0.180	-
3	1	40.329	0.972	-2.804	-0.030	-0.001	-0.535	-14.153	-0.009
	2	13.246	0.949	-0.019	-0.034	0.011	0.445	0.176	0.097
	3	9.305	0.960	-0.022	-0.032	-0.016	0.843	-0.130	-0.043
	4	0.868	0.941	-0.027	-0.033	-0.028	0.928	0.105	0.054

Çizelge 5.21 WRBA kapsamında oluşturulan tüm modellerin performansları.


Yöntem	Versiyon	Test Dönemi	RMSE	NRMSE	NMAE	%R ²
DWT-MRR	V1	Altı Ay	29.5128	0.0277	0.0207	98.02
		Bir Yıl	31.8803	0.0296	0.0230	97.83
	V2	Altı Ay	25.1645	0.0236	0.0148	98.54
		Bir Yıl	26.2980	0.0244	0.0151	98.48
	V3	Altı Ay	32.4599	0.0304	0.0240	97.95
		Bir Yıl	35.8262	0.0332	0.0270	97.69
DWT-MLR	V1	Altı Ay	29.3345	0.0275	0.0199	98.03
		Bir Yıl	31.8626	0.0294	0.0227	97.85
	V2	Altı Ay	25.1386	0.0232	0.0144	98.56
		Bir Yıl	26.2822	0.0243	0.0149	98.51
	V3	Altı Ay	31.3480	0.0298	0.0233	97.97
		Bir Yıl	35.0536	0.0329	0.0265	97.73

Altı aylık ve bir yıllık test dönemlerine ait tahmin performans göstergeleri incelendiğinde, DWT-MRR ve DWT-MLR yöntemlerinin farklı versiyonlarının doğruluk açısından anlamlı farklılıklar gösterdiği gözlemlenmiştir. Her iki yöntem açısından da V2 giriş seti kullanılarak oluşturulan modelleri, hem kısa vadeli (altı aylık) hem de uzun vadeli (bir yıllık) tahminlerde en yüksek performansı sergilemiştir. DWT-MRR yöntemi için V2 versiyonu, altı aylık dönemde en düşük RMSE, NRMSE ve NMAE değerlerini üretmiş; aynı zamanda %R² değeri açısından da en yüksek doğruluğa ulaşmıştır. Bu eğilim, bir yıllık test dönemi sonuçlarında da korunmuş; V2 versiyonu, diğer versiyonlara kıyasla daha düşük hata değerleri ve daha yüksek korelasyon katsayısı ile öne çıkmıştır. DWT-MLR yöntemi açısından da benzer bir durum söz konusudur. V2 versiyonu, altı aylık test döneminde RMSE, NRMSE ve NMAE gibi en düşük hata metriklerini sağlamış, %98.56 ile en yüksek %R² değerini elde etmiştir. Bir yıllık test döneminde ise DWT-MLR-V2 modeli aynı performansı sağlama eğilimini korumuştur.


V1 ve V3 versiyonlarıyla karşılaştırıldığında, her iki yöntemde (DWT-MRR ve DWT-MLR) de V2 versiyonunun hata oranlarını anlamlı biçimde düşürdüğü ve açıklayıcılığı

artırdığı belirlenmiştir. Özellikle V3 versiyonlarının hem DWT-MRR hem de DWT-MLR için en yüksek hata oranlarına ve en düşük $\%R^2$ değerlerine sahip olduğu dikkate alındığında, bu versiyonların model performansı açısından daha zayıf olduğu sonucuna varılmıştır.

Sonuç olarak, DWT ayrıştırmasıyla oluşturulan modeller içerisinde, hem DWT-MRR-V2 hem de DWT-MLR-V2 yöntemlerinde hem altı aylık hem de bir yıllık test dönemleri için tahmin performansı açısından en tutarlı ve başarılı sonuçları sunmuştur. Bu durum, DWT ayrıştırması sonrası uygun model giriş değişkenlerinin belirlenmesinin tahmin başarısı üzerindeki kritik rolünü ortaya koymuştur. En başarılı tahmin sonuçlarını veren DWT-MLR-V2 ile gerçekleştirilen altı aylık ve bir yıllık tahminler ile gerçek değerleri karşılaştıran grafikler sırasıyla Şekil 5.22 ve Şekil 5.23'te verilmiştir.



Şekil 5.22 DWT-MLR-V2 ile elde edilen altı aylık tahminlerin karşılaştırması.



Şekil 5.23 DWT-MLR-V2 ile elde edilen bir yıllık tahminlerin karşılaştırması.

5.5.3 Kümeleme Destekli Dalgacık ve Regresyon Tabanlı Yaklaşım ile Elde Edilen Tahmin Sonuçları

Tez kapsamında geliştirilen yaklaşımların sonuncusu olan CA-WRBA stratejisi kapsamında, WRBA'ya ek olarak kernel k-means algoritması kullanılarak belirlenen CI kümeleri — SC, C ve MC — içerisinde modellerin gösterdiği tahmin performansları ayrı ayrı analiz edilmiştir. Her bir CI kümesinde, tüm giriş veri seti versiyonları kullanılarak oluşturulan DWT-MRR ve DWT-MLR modellerinin tahmin performansları değerlendirilmiş; en yüksek doğruluk ve güvenilirlik düzeyine ulaşan modeller seçilerek hibrit bir yapı oluşturulmuştur.

Üç buçuk yıllık eğitim dönemi için Çizelge 5.22 ve Şekil 5.24'te sunulan RMSE ve $\%R^2$ değerleri, her bir bulutluluk kümesi için tüm modellerin tahmin doğruluğuna ilişkin bulguları ortaya koymaktadır. RMSE değerleri hata oranlarını doğrudan ölçerken, $\%R^2$ değeri modellerin açıklayıcılık düzeyini göstermektedir. Üç buçuk yıllık eğitim dönemi verilerine ait bu değerlendirmelerde, MC (çoğunlukla bulutlu) kümesinde en iyi tahmin performansı DWT-MLR-V2 modeliyle elde edilmiştir. Bu model, özellikle yoğun


bulutluluğun gözlemlendiği saatlerde hata oranlarını en aza indirmiştir. Orta yoğunluktaki bulutlu saatleri temsil eden C kümesinde ise DWT-MRR-V3 modeli en başarılı tahmin sonuçlarını vermiştir. SC (hafif bulutlu) kümesinde ise en yüksek performans, DWT-MLR-V1 modeliyle elde edilmiş ve bu model, gökyüzünün daha açık olduğu saatlerdeki güneş ışınımını başarılı bir şekilde tahmin etmiştir.

Çizelge 5.22 Tüm modellerin oluşturulan CI kümelerindeki performansları (üç buçuk yıllık eğitim dönemi için) (Arseven ve Çınar 2025b).

Tahmin Yöntemi	Performans Ölçütü					
	RMSE			%R ²		
	MC	C	SC	MC	C	SC
DWT-MRR-V1	30.5308	36.9454	28.1767	85.0496	97.2403	98.6608
DWT-MRR-V2	14.9830	36.8075	33.0494	98.5529	97.5504	96.1339
DWT-MRR-V3	30.6847	28.8951	32.0844	83.1277	98.1772	97.4209
DWT-MLR-V1	30.2426	36.9023	27.9698	85.1398	97.4530	98.9274
DWT-MLR-V2	14.7545	37.0218	32.9450	98.6212	97.4638	96.2563
DWT-MLR-V3	31.0181	28.9866	33.1263	82.9666	98.0224	97.2180

Benzer şekilde, üç yıllık eğitim dönemi verileriyle elde edilen sonuçlar da (Çizelge 5.23 ve Şekil 5.25) önceki dönemle tutarlılık göstermektedir. Bu durum, kullanılan model yapılarının ve giriş değişkenlerinin her bir bulutluluk düzeyi için uygun biçimde seçilmesinin, tahmin doğruluğunu artırmada kritik bir rol oynadığını ortaya koymuştur.


Bu bulgular, tahmin doğruluğunu artırmada kritik bir rol oynayan faktörün, sadece genel bir model geliştirmekten ziyade, spesifik atmosferik koşullara (yani bulutluluk düzeylerine) özgü parametre optimizasyonu olduğunu göstermektedir. Başka bir deyişle, farklı bulutluluk senaryoları için ayrı ayrı ele alınan ve bu senaryolara en uygun özellik setleri ile eğitilen modellerin, genel geçer bir yaklaşıma kıyasla daha sağlam ve güvenilir tahminler ürettiği kanıtlanmıştır. Bu da, gerçek dünya uygulamalarında karşılaşılan dinamik ve değişken atmosferik koşullar altında modelin genellenebilirliğini ve sağlamlığını pekiştirmektedir.



Şekil 5.24 Tüm tahmin modellerinin CI kümelerindeki performansları (üç buçuk yıllık eğitim dönemi için).

Çizelge 5.23 Tüm modellerin oluşturulan CI kümelerindeki performansları (üç yıllık eğitim dönemi için).


Tahmin Yöntemi	Performans Ölçütü					
	RMSE			%R²		
	MC	C	SC	MC	C	SC
DWT-MRR-V1	30.0953	36.3209	28.6455	82.5005	97.1905	98.5113
DWT-MRR-V2	13.5013	33.2027	30.9179	96.4801	95.3030	95.6228
DWT-MRR-V3	33.6533	31.6291	32.6515	78.1722	97.6452	95.1223
DWT-MLR-V1	30.0563	36.0325	28.0856	83.2816	97.0218	98.5128
DWT-MLR-V2	13.2045	35.4627	30.3563	98.6212	97.4638	96.2563
DWT-MLR-V3	33.9865	28.9866	32.8654	78.0996	97.5527	94.9850



Şekil 5.25 Tüm tahmin modellerinin CI kümelerindeki performansları (üç yıllık eğitim dönemi için).

Şekil 5.26’da, CA-WRBA kapsamında önerilen algoritma ile geliştirilen hibrit tahmin modeli kullanılarak altı aylık test dönemi için elde edilen tahmin değerleri ile gerçek değerlerin karşılaştırıldığı radar grafiklerini sunulmuştur. Şekil 5.27’de ise CA-WRBA kapsamında önerilen algoritma ile geliştirilen hibrit tahmin modeli kullanılarak bir yıllık test dönemi için elde edilen tahmin değerleri ile gerçek değerlerin karşılaştırıldığı radar grafiklerini sunulmuştur. Bu grafikler, modellerin performansına ilişkin kapsamlı bir görsel analiz sağlamıştır.

CA-WRBA kapsamında önerilen hibrit altı aylık ve bir yıllık test dönemleri için oluşturulan modellerin performansının $\%R^2$, RMSE ve standart sapma gibi temel istatistiksel metrikler üzerinden aynı anda incelenmesine olanak tanıyan Taylor diyagramları sırasıyla Şekil 5.28 ve Şekil 5.29 sunulmuştur.




Şekil 5.26 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (radar grafikleri – altı aylık test dönemi için) (Arseven ve Çınar 2025b).


Her iki şekil (Şekil 5.28 ve Şekil 5.29) için de 1, 2, 3, 4, 5, 6 ve 7 ile numaralandırılan modellerin isimleri sırasıyla şu şekildedir: DWT-MRR-V1, DWT-MRR-V2, DWT-MRR-V3, DWT-MLR-V1, DWT-MLR-V2, DWT-MRR-V3 ve CA-WRBA kapsamında önerilen hibrit modeldir. Taylor diyagramları, tahmin modelinin, gözlemlenen gerçek değerlere olan uyumunu ve tahminlerindeki varyans özelliklerini, referans noktasına göre açısal konum, merkezden uzaklık ve radyal mesafe ile göstererek kapsamlı bir değerlendirme sunmaktadır. Bu diyagramlar, modelin performansına ilişkin daha detaylı bir bakış açısı sağlayarak, modelin güvenilirliği ve doğruluğu hakkında önemli çıkarımlar yapılmasına olanak tanımıştır. Bu diyagramlar sayesinde, modellerin gözlemlenen verilerle olan korelasyonları, standart sapmaları ve tahmin hataları tek bir grafik üzerinde değerlendirilebilmekte; böylece her bir modelin genel başarı düzeyi ve güvenilirliği hakkında nicel ve görsel olarak anlamlı sonuçlara ulaşılmaktadır.



Şekil 5.27 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (radar grafikleri – bir yıllık test dönemi için).




Şekil 5.28 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (Taylor diyagramı – altı aylık test dönemi için).




Şekil 5.29 WRBA ve CA-WRBA kapsamında geliştirilen tüm modellerin nihai tahmin sonuçları (Taylor diyagramı – bir yıllık test dönemi için).

Çalışma kapsamında değerlendirilen tüm modelleme yaklaşımları arasında, en yüksek doğruluk oranına sahip tahminlerin CA-WRBA ile geliştirilen hibrit model aracılığıyla elde edildiği belirlenmiştir. Bu hibrit yapılar, farklı modelleme tekniklerinin avantajlarını bir araya getirerek tahmin başarımını anlamlı düzeyde artırmıştır. Özellikle altı aylık ve bir yıllık dönemler için gerçekleştirilen öngörülerde, söz konusu modellerin gerçek değerlerle yüksek uyum gösterdiği gözlemlenmiştir. Bu kapsamda, model tahminleri ile gözlenen değerlerin karşılaştırmalı olarak sunulduğu grafikler sırasıyla Şekil 5.30 ve Şekil 5.31’de yer almaktadır. İlgili grafikler, hibrit modellerin zaman serisi boyunca tutarlılığı koruyarak öngörü performansını sürdürdüğünü ortaya koymuştur.

Tezde değerlendirilen tüm modelleme yaklaşımları arasında, en yüksek doğruluk oranı CA-WRBA tabanlı hibrit modelle elde edilmiştir. Bu model, farklı yöntemlerin güçlü yönlerini birleştirerek tahmin başarımını anlamlı şekilde artırmış ve özellikle altı aylık ve bir yıllık öngörülerde gözlenen verilerle yüksek uyum sergilemiştir. Şekil 5.30 ve Şekil 5.31’de sunulan grafikler, hibrit modelin zaman serisi boyunca öngörü tutarlılığını koruduğunu açıkça ortaya koymaktadır.



Şekil 5.30 CA-WRBA kapsamında önerilen model ile elde edilen altı aylık tahminlerin karşılaştırması.



Şekil 5.31 CA-WRBA kapsamında önerilen model ile elde edilen bir yıllık tahminlerin karşılaştırması.

6. SONUÇLAR

Güneş enerjisi sistemlerinin etkin yönetimi ve enerji şebekelerinin dengelenmesi açısından kısa dönemli güneş ışıınımı tahmini, kritik bir öneme sahiptir. Özellikle saatlik bazda yapılacak doğru tahminler, anlık enerji üretimi planlaması ve şebeke entegrasyonu süreçlerinde operasyonel verimliliği artırabilmektedir. Bu bağlamda, tez çalışması kapsamında bir saat sonrası güneş ışıınımını öngörmek amacıyla üç farklı yaklaşım geliştirilmiştir. Tez kapsamında kısa dönemlik (bir saat sonrası) güneş ışıınım tahmini için üç farklı yaklaşım geliştirilmiştir. İlk olarak temel regresyon tabanlı yaklaşım (Basic Regression Based Approach-BRBA) kapsamında, Afyon Bölge İstasyonu'ndan (ABİ) elde edilen saatlik formattaki ışıınım, ortalama hava sıcaklığı ve bağıl nem verileri kullanılarak çok değişkenli regresyon temelli tahmin modelleri oluşturulmuştur. Bu süreçte, çok değişkenli ridge regresyon (Multivariate Ridge Regression-MRR) ve çok değişkenli lasso regresyon (Multivariate Lasso Regression-MLR) yöntemlerinden yararlanılmıştır. Amaç, farklı meteorolojik değişken kombinasyonlarının, sonraki saate ait güneş ışıınımı değerlerini ne ölçüde doğru tahmin edebildiğini ortaya koymaktır.

Daha sonra belirlenen ikincil strateji olan dalgacık ve regresyon tabanlı yaklaşım (Wavelet and Regression Based Approach-WRBA) kapsamında saatlik ışıınım, ortalama hava sıcaklığı ve bağıl nem verileri, tek boyutlu ayrık dalgacık dönüşümü (Discrete Wavelet Transform-DWT) tekniği kullanılarak farklı seviyelerde ayrıştırılmıştır. Bu dönüşüm ile her bir değişken, düşük frekanslı (yaklaşık bileşen) ve yüksek frekanslı (detay bileşenleri) bileşenlere ayrılarak daha ayrıntılı bir yapıda temsil edilmiştir. Elde edilen bu alt sinyaller, orijinal verinin hem kısa süreli dalgalanmalarını hem de genel eğilimlerini daha açık biçimde modellemeye olanak tanımıştır. Dalgacık dönüşümünde, verilerin genel yapıları ile yüksek düzeyde benzerlik gösterdiği db10 dalgacığı tercih edilmiştir. Bu dalgacık türünün seçilmesindeki temel gerekçe, kullanılan meteorolojik zaman serilerinin frekans dağılımları ve sinyal pürüzsüzlüğü açısından db10 dalgacığıyla yapısal uyum göstermesidir. Ayrıca, her bir değişken için birinci, ikinci, üçüncü ve dördüncü seviyelerde tek boyutlu DWT ayrıştırması gerçekleştirilmiştir. Bu ayrıştırma işlemlerinin sonrasında, her bir alt sinyal bileşeni için birbirinden bağımsız MRR ve MLR modelleri (DWT-MRR ve DWT-MLR modelleri) geliştirilmiştir. WRBA kapsamında da,

BRBA'da tanımlanan Versiyon-1 (V1), Versiyon-2 (V2) ve Versiyon-3 (V3) giriş değişkeni kombinasyonlarına sadık kalınarak, bu kombinasyonlar DWT ile ayrıştırılmış alt sinyaller üzerinde uygulanarak değerlendirme yapılmıştır. Bu sayede, veri ayrıştırmasının tahmin doğruluğuna katkısı ve regresyon modellerinin frekans temelli veri temsilleriyle etkileşimi değerlendirilmiştir.

Son olarak geliştirilen kümeleme destekli dalgacık ve regresyon tabanlı yaklaşım (Cluster Assisted Wavelet and Regression Based Approach, CA-WRBA) stratejisi kapsamında ise ilk olarak, güneş ışıınımı, ortalama hava sıcaklığı ve bağıl nem verileri, tek boyutlu DWT yöntemi kullanılarak farklı seviyelerde ayrıştırılmıştır. Üç farklı giriş kombinasyonundan elde edilen alt sinyaller için uygun tahmin modelleri belirlenmiş ve bu alt sinyaller üzerinden tahminler gerçekleştirilmiştir. Daha sonra alt sinyal tahminleri birleştirilerek her model için ana tahmin sinyalleri elde edilmiştir. Buna ek olarak, bir sonraki saate ait açıklık endeksi (Clearness Index-CI) değerleri de tahmin edilmiştir. Eğitim verilerindeki CI değerleri kullanılarak üç farklı bulutluluk kümesi çeşitli kümeleme algoritmaları ile oluşturulmuştur. CI kümelenmesi sonucunda, kernel k-means algoritmasıyla her küme için en başarılı tahmin modeli belirlenmiştir. Bu kapsamda, çok bulutlu (Mostly Cloudy-MC) küme için en iyi tahmin performansı DWT-MLR-V2 modeliyle, bulutlu (Cloudy-C) küme için DWT-MRR-V3 modeliyle ve az bulutlu (Slightly Cloudy-SC) küme için DWT-MLR-V1 modeliyle elde edilmiştir. Bu modellerin hibritlenmesiyle nihai tahmin performansı iyileştirilmiştir. Önerilen tahmin algoritmasının çalıştırılması sonucunda, CI kümelenmesi uygulanmaksızın elde edilen en iyi performansa sahip DWT-MLR-V2 modelinin kök ortalama karesel hata (Root Mean Square Error-RMSE) değeri 25.1386 W/m² iken, kümelere özgü en iyi tahmin modellerinin uygulanmasıyla bu değer 20.8154 W/m²'ye düşürülmüştür.

Sonuç olarak aşağıdaki çıkarımlara ulaşılmıştır:

- Farklı tek boyutlu DWT seviyeleri analiz edilerek en iyi tahmin performansı sağlayan ayrıştırma seviyesi belirlenmiştir. Bulgular, birinci seviyede tek boyutlu DWT ile ayrıştırılmış sinyaller kullanılarak oluşturulan modeller ile en yüksek tahmin doğruluğunun sağlandığını göstermiştir. Benzer konularda yapılan önceki

arařtırmaların, DWT ayrıştırma seviyesinin seçimi konusunda kapsamlı bir açıklama veya analitik temel sunmadığı tespit edilmiştir. Bu eksiklik, bu tezde yer alan ayrıştırma seviyesi seçimine ilişkin sağlam bir analiz ve gerekçelendirme sunarak literatürdeki önemli bir boşluğu doldurduğunu ortaya koymuştur. Ayrıca bu bulgu, ileride yapılacak çalışmalarda ayrıştırma kaynaklı hesaplama yükünün azaltılabileceğine de böylece işaret etmiştir.

- Farklı giriş değişkenleriyle oluşturulan tahmin modellerinin, belirlenen bulutluluk kümeleri içerisinde gösterdiği performanslar değerlendirilmiştir. Bu bağlamda, belirli giriş değişkenlerinin, bulutluluk düzeyine göre daha doğru tahminler sunduğu belirlenmiştir. Bu durum, daha doğru tahminler elde edebilmek için model giriş değişkenlerinin bulutluluk düzeylerine göre uyarlanması gerektiğini ortaya koymuştur. Giriş değişkenlerinin her bulutluluk seviyesinin kendine özgü koşullarıyla uyumlu olacak şekilde belirlenmesi, modellerin güneş ışıınımını etkileyen faktörleri daha etkili bir biçimde yakalamasına olanak tanımış ve tahmin doğruluğunu artırmıştır. Bu yaklaşım, hava durumu desenlerindeki değişkenliğe uyum sağlayacak esneklikte model tasarımının önemini vurgulamıştır.
- MC kümesinde en doğru tahmin sonuçları, giriş değişkenleri olarak ışıınım ve bağıl nemin kullanıldığı DWT-MLR-V2 modeli ile elde edilmiştir. Bu durum, bağıl nemin tahmin başarısını artıran kritik bir değişken olduğunu göstermektedir. Özellikle bulut örtüsü seviyeleri dikkate alındığında, bağıl nemdeki artışın genellikle bulutluluğu da artırması, bu değişkenin güneş ışıınımı üzerindeki dolaylı etkisini güçlendirmektedir. Bu nedenle, bağıl nemin modele dahil edilmesi, özellikle bulutlu koşullarda ışıınım tahmin doğruluğunu anlamlı ölçüde iyileştirmiştir.
- SC kümesinde, güneş ışıınımı ve ortalama hava sıcaklığı verilerinin model girişlerinde kullanıldığı DWT-MLR-V1 modeli, en doğru tahmin sonuçlarını vermiştir. Bu başarı, açık gökyüzü koşullarında güneş ışıınımı ile hava sıcaklığı arasındaki etkileşimin daha belirgin hale gelmesinden kaynaklanmaktadır. Açık hava koşullarında atmosferik etkilerin minimumda olması, güneş ışıınımının yüzeye daha yüksek oranda geçişine olanak tanımakta ve bu da yüzey sıcaklığının artmasına neden olmaktadır. Dolayısıyla, bu koşullarda güneş ışıınımı ile sıcaklık

arasındaki ilişki daha güçlü bir yapıya bürünmekte, bu da model performansına olumlu yansımaktadır.

- Sonuç olarak, gerçekleştirilen analizler bulut örtüsü seviyeleri ile meteorolojik değişkenler arasındaki ilişkiyi ortaya koyarak, geliştirilen yöntemlerin etkinliğini artırmaya yönelik önemli bulgular sunmuştur. Bu bulgular, güneş ışıınımı tahminlerinde daha başarılı sonuçların elde edilmesine katkı sağlamıştır.

Gelecek çalışmalar, bu çalışmanın bulguları ve metodolojik yaklaşımı üzerine inşa edilerek daha kapsamlı analizlere odaklanabilir. Özellikle birinci seviye tek boyutlu DWT ayrıştırmasının sağladığı üstün tahmin doğruluğunun farklı meteorolojik ve coğrafi koşullarda da geçerli olup olmadığının araştırılması önem arz etmektedir. Ayrıca, daha büyük veri kümeleriyle farklı bulutluluk düzeylerine göre optimize edilmiş model giriş değişkenlerinin incelenmesi, çeşitli hava koşullarında daha sağlam ve güvenilir modellerin geliştirilmesine katkı sağlayabilir. Bağıl nem, sıcaklık ve diğer meteorolojik faktörlerin dinamik etkilerinin daha ayrıntılı olarak analiz edilmesi, mevcut modellerin doğruluğunu artırabilir ve farklı mevsimsel ve coğrafi değişkenliklere uyarlanabilir genel geçer tahmin yöntemlerinin oluşturulmasına olanak tanıyabilir.

7. KAYNAKLAR

- Aguiar-Conraria L, Soares M J, 2014, The Continuous Wavelet Transform: Moving Beyond Uni-and Bivariate Analysis, *Journal of Economic Surveys*, 28, 344-375.
- Akaike H, 1998, *Information Theory and An Extension of The Maximum Likelihood Principle* (Ed.), Springer.
- Akarslan E, Hocaoglu F O, Edizkan R, 2018, Novel Short Term Solar Irradiance Forecasting Models, *Renewable Energy*, 123, 58-66.
- Ali M, Prasad R, Xiang Y, Khan M, Farooque A A, Zong T vd.Yaseen Z M, 2021, Variational Mode Decomposition Based Random Forest Model for Solar Radiation Forecasting: New Emerging Machine Learning Technology, *Energy Reports*, 7, 6700-6717.
- Alizamir M, Shiri J, Fard A F, Kim S, Gorgij A D, Heddami S, Singh V P, 2023, Improving the Accuracy of Daily Solar Radiation Prediction by Climatic Data Using An Efficient Hybrid Deep Learning Model: Long Short-Term Memory (LSTM) Network Coupled with Wavelet Transform, *Engineering Applications of Artificial Intelligence*, 123, 106199.
- Almorox J, Hontoria C, 2004, Global Solar Radiation Estimation Using Sunshine Duration in Spain, *Energy Conversion and Management*, 45, 1529-1535.
- Anupong W, Jweeg M J, Alani S, Al-Kharsan I H, Alviz-Meza A, Cárdenas-Escrocia Y, 2023, Comparison of Wavelet Artificial Neural Network, Wavelet Support Vector Machine, and Adaptive Neuro-Fuzzy Inference System Methods in Estimating Total Solar Radiation in Iraq, *Energies*, 16, 985.
- Arseven B, Çınar S M, 2025, Dünya Dışı Işınlam Destekli Çok Değişkenli Ridge ve Lasso Regresyon Yöntemleri ile Güneş Işınlamı Tahmini, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 40, 1745-1756, Basımda.
- Arseven B, Çınar S M, 2023, Dünya Dışı Işınlamla İyileştirilmiş ARIMA, Ridge Regresyon ve Lasso Regresyon Yöntemlerinin Saatlik Işınlam Tahmininde Kullanılması, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12, 733-742.

- Arseven B, Çınar S, 2025a, Short-Term Solar Radiation Forecasting with Discrete Wavelet Transform Based Boosted Machine Learning Methods. *Proceedings of the Bulgarian Academy of Sciences*, 78, 543–551.
- Arseven B, Çınar S M, 2025b, A Novel Hybrid Solar Radiation Forecasting Algorithm Based on Discrete Wavelet Transform and Multivariate Machine Learning Models Integrated with Clearness Index Clusters, *Journal of Atmospheric and Solar-Terrestrial Physics*, 106417.
- Aydın K, 2024, Yenilenebilir Enerjiye Yönelik Mali Teşvikler; Türkiye ve Seçili Ülkeler Karşılaştırılması, Sakarya Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 147s, Sakarya.
- Ayodele T, Ogunjuyigbe A, Amedu A, Munda J, 2019, Prediction of Global Solar Irradiation Using Hybridized K-Means and Support Vector Regression Algorithms, *Renewable Energy Focus*, 29, 78-93.
- Bamisile O, Ejiyi C J, Osei-Mensah E, Chikwendu I A, Li J, Huang Q, Long-Term Prediction of Solar Radiation Using Xgboost, LSTM, and Machine Learning Algorithms, 4th Asia Energy and Electrical Engineering Symposium (AEEES), 2022, March 25-28, Chengdu.
- Band S S, Qasem S N, Ameri R, Pai H-T, Gupta B B, Mehdizadeh S vd. Mosavi A, 2024, Deep Learning Hybrid Models With Multivariate Variational Mode Decomposition for Estimating Daily Solar Radiation, *Alexandria Engineering Journal*, 105, 613-625.
- Barbón A, Aparicio-Bermejo J, Bayón L, Ayuso P F, 2025, The Optimal Design for Photovoltaic Power Plants on Sites with A General Slope, *Applied Energy*, 387, 125582.
- Besharat F, Dehghan A A, Faghih A R, 2013, Empirical Models for Estimating Global Solar Radiation: A Review and Case Study, *Renewable and Sustainable Energy Reviews*, 21, 798-821.
- Brassington G, 2017, Mean Absolute Error and Root Mean Square Error: Which Is The Better Metric for Assessing Model Performance?, *EGU general assembly conference abstracts*: 3574.

- Cao J C, Cao S, 2006, Study of Forecasting Solar Irradiance Using Neural Networks with Preprocessing Sample Data by Wavelet Analysis, *Energy*, 31, 3435-3445.
- Chen R, Ersi K, Yang J, Lu S, Zhao W, 2004, Validation of Five Global Radiation Models with Measured Daily Data in China, *Energy Conversion and Management*, 45, 1759-1769.
- Chodakowska E, Nazarko J, Nazarko Ł, Rabayah H S, Abende R M, Alawneh R, 2023, Arima Models in Solar Radiation Forecasting in Different Geographic Locations, *Energies*, 16, 5029.
- Christophorou L G, *Energy, Environment and Modern Civilization, International Conference on Transition to a New Society*, 2014, March 20-22, Podgorica.
- Colak I, Yesilbudak M, Genc N, Bayindir R, 2015, Multi-Period Prediction of Solar Radiation Using ARMA and ARIMA Models, *IEEE 14th international conference on machine learning and applications (ICMLA)*, 2015, December 9-11, Miami.
- Copeland A W, Black O D, Garrett A, 1942, The Photovoltaic Effect, *Chemical Reviews*, 31, 177-226.
- Çepik B, 2015, Sürdürülebilir Kalkınma Çerçevesinde Türkiye'de Yenilenebilir Enerji Politikaları, *Maltepe Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi*, 136s, İstanbul.
- Çınar S M, Arseven B, 2021, Kısmi Gölgeleme Etkilerini Modelleyebilen Bir PV Emülatör Tasarımı, *Journal of the Institute of Science and Technology*, 11, 982-997.
- Debroy S, Ahmed I, Kokoricha P, Lu X, Zhang L, Chen Y, O'Sullivan A, Alasmar R vd.Gharavi A, Predicting the Wholesale Electricity Pricing in Germany Using Weather and Renewable Energy Variables, Available at SSRN 5145601.
- DeCarlo L T, 1997, On The Meaning and Use of Kurtosis, *Psychological Methods*, 2, 292.
- Demirkol Z, Cunkaş M, 2014, Afyonkarahisar ili yenilenebilir enerji potansiyeli, *Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi*, 2, 45-56.

- Deo R C, Wen X, Qi F, 2016, A Wavelet-Coupled Support Vector Machine Model for Forecasting Global Incident Solar Radiation Using Limited Meteorological Dataset, *Applied Energy*, 168, 568-593.
- Edwards T, 1991, *Discrete Wavelet Transforms: Theory and Implementation*, Stanford University, 28-35.
- Elsayed A, Elshinawy M Y, Ibrahim N, Woodall R, Badawy A-H A, Ranade S, Regression Models for Solar Radiation Prediction, *Congress in Computer Science, Computer Engineering, & Applied Computing (CSCE)*, 2023, July 24-27, Las Vegas.
- Enebe G C, Ukoba K, Jen T-C, 2024, A Review of Numerical Tools for Solar Cells, Localized Energy Transition in the 4th Industrial Revolution, 68-85.
- Eşlik A H, Akarslan E, Hocaoglu F O, 2021, Güneş Işınımı Tahmininde Ayrıştırma-Birleştirme Öğrenme Yaklaşımı, *Journal of the Institute of Science and Technology*, 11, 132-144.
- Garver M, 1916, The Current "Definition" of Energy, *Science*, 43, 567-571.
- Ge Y, Nan Y, Bai L, 2019, A Hybrid Prediction Model for Solar Radiation Based on Long Short-Term Memory, Empirical Mode Decomposition, and Solar Profiles for Energy Harvesting Wireless Sensor Networks, *Energies*, 12, 4762.
- Ghimire S, Nguyen-Huy T, Deo R C, Casillas-Perez D, Salcedo-Sanz S, 2022, Efficient Daily Solar Radiation Prediction with Deep Learning 4-Phase Convolutional Neural Network, Dual Stage Stacked Regression and Support Vector Machine CNN-REGST Hybrid Model, *Sustainable Materials and Technologies*, 32.
- Ghofrani M, Ghayekhloo M, Azimi R, 2016, A Novel Soft Computing Framework for Solar Radiation Forecasting, *Applied Soft Computing*, 48, 207-216.
- Graps A, 1995, An Introduction to Wavelets, *IEEE Computational Science and Engineering*, 2, 50-61.
- Groeneveld R A, Meeden G, 1984, Measuring Skewness and Kurtosis, *Journal of the Royal Statistical Society Series D: The Statistician*, 33, 391-399.
- Gujarati D N, Porter D C, 2009, *Basic econometrics*, McGraw-Hill, 946p, New York.

- Hao Y, Lu J, Peng G, Wang M, Li J, Wei G, 2024, F10.7 Daily Forecast Using LSTM Combined with VMD Method, *Space Weather*, 22.
- Hersch P, Zweibel K, 1982, *Basic Photovoltaic Principles and Methods*, 71p, Washington.
- Hocaoğlu F O, Gerek Ö N, Kurban M, 2008, Hourly Solar Radiation Forecasting Using Optimal Coefficient 2-D Linear Filters and Feed-Forward Neural Networks, *Solar Energy*, 82, 714-726.
- Hodson T O, 2022, Root Mean Square Error (RMSE) or Mean Absolute Error (MAE): When to Use Them or Not, *Geoscientific Model Development Discussions*, 1-10.
- Hoerl A E, Kennard R W, 1970, Ridge Regression: Biased Estimation for Nonorthogonal Problems, *Technometrics*, 12, 55-67.
- Huang N E, Wu Z, 2008, A Review on Hilbert-Huang Transform: Method and Its Applications to Geophysical Studies, *Reviews of Geophysics*, 46.
- Ibrahim S, Daut I, Irwan Y, Irwanto M, Gomesh N, Farhana Z, 2012, Linear Regression Model in Estimating Solar Radiation in Perlis, *Energy Procedia*, 18, 1402-1412.
- Iqbal M, 2012, *An Introduction to Solar Radiation*, Elsevier, 389p, New York.
- Jain A K, 2010, Data Clustering: 50 Years Beyond K-means, *Pattern Recognition Letters*, 31, 651-666.
- James G, 2013, *An Introduction to Statistical Learning*, Springer, 441p, New York.
- Jarque C M, Bera A K, 1980, Efficient Tests for Normality, Homoscedasticity and Serial Independence of Regression Residuals, *Economics Letters*, 6, 255-259.
- Jin Z, Yezheng W, Gang Y, 2005, General Formula for Estimation of Monthly Average Daily Global Solar Radiation in China, *Energy Conversion and Management*, 46, 257-268.
- Johnson F S, 1954, The Solar Constant, *Journal of Atmospheric Sciences*, 11, 431-439.
- Jumin E, Basaruddin F B, Yusoff Y B M, Latif S D, Ahmed A N, 2021, Solar Radiation Prediction Using Boosted Decision Tree Regression Model: A Case Study in Malaysia, *Environmental Science and Pollution Research*, 28, 26571-26583.
- Kapluhan E, 2015, Enerji Coğrafyası Açısından Bir İnceleme: Güneş Enerjisinin Dünya'daki ve Türkiye'deki Kullanım Durumu, *Coğrafya Dergisi*, 29, 70-98.

- Kervankıran İ, 2011, Afyonkarahisar İlinde Alternatif Tarım Çalışmalarına Bir Örnek: Jeotermal Seracılık, Marmara Coğrafya Dergisi, 24, 382-402.
- Kim H, Park S, Park H-J, Son H-G, Kim S, 2023, Solar Radiation Forecasting Based on The Hybrid CNN-Catboost Model, Ieee Access, 11, 13492-13500.
- Kong X, Du X, Xue G, Xu Z, 2023, Multi-Step Short-Term Solar Radiation Prediction Based on Empirical Mode Decomposition and Gated Recurrent Unit Optimized Via An Attention Mechanism, Energy, 282.
- Lauret P, Alonso-Suárez R, Le Gal La Salle J, David M, 2022, Solar Forecasts Based on The Clear Sky Index or The Clearness Index: Which Is Better? Solar, 2, 432-444.
- Loutfi H, Bernatchou A, Raoui Y, Tadili R, 2017, Learning Processes To Predict The Hourly Global, Direct, and Diffuse Solar Irradiance From Daily Global Radiation with Artificial Neural Networks, International Journal of Photoenergy, 2017, 4025283.
- Lu Y, Wang L, Zhu C, Zou L, Zhang M, Feng L vd.Cao Q, 2023, Predicting Surface Solar Radiation Using A Hybrid Radiative Transfer–Machine Learning Model, Renewable and Sustainable Energy Reviews, 173, 113105.
- Maham F E, Akarslan E, 2022, Güneş Işınım Tahmini için Farklı Güneşlenme Durumlarından Faydalanan Hibrit Bir Yöntem Tasarımı, Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, 22, 588-596.
- Majumder I, Dash P, Bisoi R, 2018, Variational Mode Decomposition Based Low Rank Robust Kernel Extreme Learning Machine for Solar Irradiation Forecasting, Energy Conversion and Management, 171, 787-806.
- Malik M A, Kiyani O, Srinivasan A, Makarov S, 2010, Alternative Solar Cells and Their Implications, An Interactive Qualifying Project, Worcester Polytechnic Institute, Degree of Bachelor of Science, 60p, Worcester.
- Marquardt D W, Snee R D, 1975, Ridge Regression in Practice, The American Statistician, 29, 3-20.
- Mecibah M S, Boukelia T E, Tahtah R, Gairaa K, 2014, Introducing The Best Model for Estimation The Monthly Mean Daily Global Solar Radiation on A Horizontal

- Surface (Case Study: Algeria), *Renewable and Sustainable Energy Reviews*, 36, 194-202.
- Meyer Y, 1992, *Wavelets and Operators*, Cambridge University Press, Cambridge.
- Meza F, Varas E, 2000, Estimation of Mean Monthly Solar Global Radiation As A Function of Temperature, *Agricultural and Forest Meteorology*, 100, 231-241.
- Moreno-Munoz A, De La Rosa J, Posadillo R, Pallares V, 2008, Short Term Forecasting of Solar Radiation, *IEEE International Symposium on Industrial Electronics*, 2008, June 30-July 2, Cambridge.
- Ogbuabor G, Ugwoke F, 2018, Clustering Algorithm for A Healthcare Dataset Using Silhouette Score Value, *International Journal of Computer Science and Information Technology*, 10, 27-37.
- Özdemir O, 2020, Gelir ve Yaşam Koşulları Verisinin Veri Madenciliği Yaklaşımı ile İncelenmesi ve Model Performanslarının Değerlendirilmesi, *Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi*, 173s, İstanbul.
- Percival D B, Walden A T, 2000, *Wavelet Methods for Time Series Analysis*, Cambridge University Press, Cambridge.
- Prasad R, Ali M, Kwan P, Khan H, 2019, Designing A Multi-Stage Multivariate Empirical Mode Decomposition Coupled with Ant Colony Optimization and Random Forest Model To Forecast Monthly Solar Radiation, *Applied Energy*, 236, 778-792.
- Rahman M F, Tasdid M M, Fadhali M M, Sharma M, Akermi M, 2025, Unlocking Cesium Based New Double Absorber Perovskite Solar Cells with Efficiency Above 28% For Next Generation Solar Cell, *Photonics and Nanostructures-Fundamentals and Applications*, 64, 101371.
- Saleh A M E, Arashi M, Kibria B G, 2019, *Theory of Ridge Regression Estimation with Applications*, John Wiley & Sons, 362p, Hoboken.
- Sani Salisu M W M, Mustapha M, Mohammed O O, 2019, Solar Radiation Forecasting in Nigeria Based on Hybrid PSO-ANFIS and WT-ANFIS Approach, *International Journal of Electrical and Computer Engineering*, 9, 3916-3926.

- Sansa I, Boussaada Z, Mazigh M, Bellaaj N M, 2020, Solar Radiation Prediction for A Winter Day Using ARMA Model, 6th IEEE International Energy Conference (ENERGYCon), 2020, December 4-6, Batman.
- Sifuzzaman M, Islam M R, Ali M, 2009, Application of Wavelet Transform and Its Advantages Compared To Fourier Transform, Journal of Physical Sciences, 13, 121-134.
- Singh H, 2024, Machine Learning Application of Generalized Gaussian Radial Basis Function and Its Reproducing Kernel Theory, Mathematics, 12, 829.
- Stein J S, Hansen C W, Reno M J, 2012, Global Horizontal Irradiance Clear Sky Models: Implementation and Analysis, Sandia Report.
- Strang G, Nguyen T, 1996, Wavelets and Filter Banks, Wellesley-Cambridge Press, 500p, Cambridge.
- Sundararajan D, 2016, Discrete Wavelet Transform: A Signal Processing Approach, John Wiley & Sons, 323p, Singapore.
- Tibshirani R, 1996, Regression Shrinkage and Selection Via The Lasso, Journal of the Royal Statistical Society Series B: Statistical Methodology, 58, 267-288.
- Urry J, 2014, The Problem of Energy, Theory, Culture & Society, 31, 3-20.
- van Wieringen W N, 2015, Lecture Notes on Ridge Regression, arXiv preprint arXiv:1509.09169.
- Vonesch C, Blu T, Unser M, 2007, Generalized Daubechies Wavelet Families, IEEE Transactions on Signal Processing, 55, 4415-4429.
- Vrieze S I, 2012, Model Selection and Psychological Theory: A Discussion of The Differences Between The Akaike Information Criterion (AIC) and The Bayesian Information Criterion (BIC), Psychological Methods, 17, 228.
- Wei D, 1998, Coiflet-Type Wavelets: Theory, Design, and Applications, The University of Texas at Austin, Doktora Tezi, 139p, Texas.
- Willmott C J, Matsuura K, 2005, Advantages of The Mean Absolute Error (MAE) Over The Root Mean Square Error (RMSE) in Assessing Average Model Performance, Climate Research, 30, 79-82.

Wu Z, Huang N E, 2009, Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method, Advances in Adaptive Data Analysis, 1, 1-41.

Yakut E, 2012, Veri Madenciliği Tekniklerinden C5. 0 Algoritması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, 238s, Erzurum.

İnternet Kaynakları

1- <https://gepa.enerji.gov.tr/MyCalculator/>, 19.06.2025



- Çınar S M, Arseven B, 2021, Kısmi Gölgeleme Etkilerini Modelleyebilen Bir PV Emülatör Tasarımı, Journal of the Institute of Science and Technology, 11, 982-997.
- Arseven B, Çınar S M, 2023, Dünya Dışı Işınlımlarla İyileştirilmiş ARIMA, Ridge Regresyon ve Lasso Regresyon Yöntemlerinin Saatlik Işınlım Tahmininde Kullanılması, Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 12, 733-742.
- Arseven B, Çınar S, 2025, Short-Term Solar Radiation Forecasting with Discrete Wavelet Transform Based Boosted Machine Learning Methods, Proceedings of the Bulgarian Academy of Sciences, 78, 543–551.
- Arseven B, Çınar S M, 2025, A Novel Hybrid Solar Radiation Forecasting Algorithm Based on Discrete Wavelet Transform and Multivariate Machine Learning Models Integrated with Clearness Index Clusters, Journal of Atmospheric and Solar-Terrestrial Physics, 106417.
- Arseven B, Çınar S M, 2025, Dünya Dışı Işınlım Destekli Çok Değişkenli Ridge ve Lasso Regresyon Yöntemleri ile Güneş Işınlımı Tahmini, Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 40, 1745-1756.