

ÇUKUROVA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**Yüzeye Gelen Günlük Güneş Radyasyonunun Uydudan Elde
Edilen Bulutluluk İndeksi ile Tahmini**

Sedat YILMAZ

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Mayıs, 2026

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ONAYI

**Yüzeye Gelen Günlük Güneş Radyasyonunun Uydudan Elde
Edilen Bulutluluk İndeksi ile Tahmini**

Sedat YILMAZ

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Bu Yüksek Lisans Tezi 27/04/2026 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Değerlendirilmiş ve Oy Birliği / Oy Çokluğu ile Kabul Edilmiştir.

Jüri : Prof. Dr. H. Mustafa KANDIRMAZ (Danışman)
: Prof. Dr. Nazım AKSAKER
: Doç. Dr. Fatih KILIÇ

**Bu Tez Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim
Dalında Hazırlanmıştır.**

Tez No:

Prof. Dr. Sadık DİNÇER
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak
gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZ	I
ABSTRACT	II
TEŞEKKÜR	III
ÇİZELGELER DİZİNİ	IV
ŞEKİLLER DİZİNİ	V
SİMGELER VE KISALTMALAR	VI
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	3
3. MATERYAL VE METOT	7
3.1. Materyal	7
3.1.1. Yer Ölçümleri	8
3.1.2. Meteorolojik Uydu Verileri	12
3.1.3. EUMETSAT ve Meteosat Uyduları	13
3.1.4. CM SAF CLAAS-3 Parçalı Bulut Örtüsü (CFC) Ürünü	16
3.2. Metot	19
3.2.1. Yapay Sinir Ağları	19
3.2.2. Karar Ağaçları ve LightGBM	22
3.2.3. Gün Uzunluğunun Tanımlanması	23
3.2.4. Performans Hata Metrikleri	24
4. BULGULAR VE TARTIŞMA	25
4.1. Yer Kayıtlarının Çalışma İçin Hazırlanması	25
4.2. Uydu Ürününün Çalışma İçin Hazırlanması	29
4.3. Gün Uzunluğunun Çalışma İçin Hazırlanması	31
4.4. Yapay Sinir Ağlarının Oluşturulması ve Bulgular	31
4.5. LightGBM Oluşturulması ve Bulgular	37
5. SONUÇLAR VE ÖNERİLER	43
KAYNAKLAR	47
ÖZGEÇMİŞ	49
EKLER	51
Ek-1: Tez adlı veri tabanının yapısı	53
Ek-2: 244 İstasyona Ait Tanımlayıcı Bilgiler Ve Coğrafi Konumlar	56
Ek-3: Yer Ölçüm Güneş Radyasyonlarının Veri Tabanına Aktarılması İçin Arayüz Ve Makro	62
Ek-4: Bilinear İnterpolasyon İle Bulutluluk İndeks Hesabı İçin Python Kodu	66
Ek-5: En Yakın Komşu İle Bulutluluk İndeks Hesabı İçin Python Kodu	69
Ek-6: İstasyonların Gün Uzunluğu Hesabı İçin Python Kodu	72

Ek-7: Python Yapay Sinir Ağları Model Kodu.....	75
Ek-8: Python LightGBM Model Kodu	83



Yüzeye Gelen Günlük Güneş Radyasyonunun Uydudan Elde Edilen Bulutluluk İndeksi ile Tahmini

Sedat YILMAZ

Danışman: Prof. Dr. H. Mustafa KANDIRMAZ

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

ÖZ

Küresel enerji talebindeki artış ve temiz enerjiye yönelim, yüzeye ulaşan güneş radyasyonunun yüksek doğrulukla izlenmesini kritik hale getirmiştir. Bu çalışma, yer gözlem istasyonlarının kısıtlı dağılımı ve bulutluluk kaynaklı belirsizlikleri aşmak amacıyla, uydu verilerini makine öğrenmesi yöntemlerine entegre ederek Türkiye geneli için güneş radyasyon tahmin modeli geliştirmeyi hedeflemektedir. Araştırmada, 244 istasyondan alınan 2023-2024 dönemi günlük yer gözlemleri ile MSG/SEVIRI uydusu tabanlı CLAAS-3 (Edition 3) bulutluluk verileri kullanılarak Yapay Sinir Ağları ve LightGBM algoritmaları değerlendirilmiştir. Veri ön işleme sürecinde, modele sadece gün uzunluğu parametresinin eklenmesi R^2 skorunu %32'den %62'ye çıkarmıştır. Coğrafi koordinat ve zamansal değişkenlerin dahil edilmesi ise performansı önemli bir artışla %85 seviyelerine taşımıştır. Çalışmada en yüksek başarıyı $R^2 = 0,85$, RMSE = 0,8 kWh/m² ve MAE = 0,6 kWh/m² değerleriyle LightGBM modeli vermiştir. Sonuç olarak bu çalışma uydu tabanlı bulutluluk indeksi verilerinin makine öğrenmesi ile işlenmesinin ölçüm istasyonu bulunmayan bölgeler için güneş enerjisi potansiyelinin belirlenmesinde bir alternatif olarak kullanılabileceğini ortaya koymuştur.

Anahtar Kelimeler: Güneş Radyasyonu, MSG/SEVIRI, Yapay Sinir Ağları, LightGBM, CLAAS-3

Estimation of Daily Solar Radiation Using The Satellite-Derived Cloud Cover Index

Sedat YILMAZ

Advisor: Prof. Dr. H. Mustafa KANDIRMAZ

Department of Remote Sensing and Geographic Information Systems

ABSTRACT

The increase in global energy demand and the shift towards clean energy have made the high-accuracy monitoring of surface solar radiation critical. This study aims to develop a solar radiation estimation model for Turkey by integrating satellite data with machine learning methods to overcome the limited distribution of ground observation stations and uncertainties caused by cloud cover. In the research, Artificial Neural Networks (ANN) and LightGBM algorithms were evaluated using daily ground observations from 244 stations between 2023-2024 and CLAAS-3 (Edition 3) cloud cover data based on the MSG/SEVIRI satellite. During the data preprocessing stage, adding only the day length parameter to the model increased the R2 score from 32% to 62%. The inclusion of geographic coordinates and temporal variables further improved the performance, reaching the 85% level. The LightGBM model achieved the highest success with $R^2 = 0.85$, $RMSE = 0.8 \text{ kWh/m}^2$, and $MAE = 0.6 \text{ kWh/m}^2$. Consequently, this study demonstrates that processing satellite-based cloud index data with machine learning can be used as a reliable alternative for determining solar energy potential in regions lacking measurement stations.

Keywords: Solar Radiation, MSG/SEVIRI, Artificial Neural Networks, LightGBM, CLAAS-3

TEŞEKKÜR

Yüksek Lisans eğitimim ve tez çalışmamın her aşamasında engin bilgi ve tecrübeleriyle bana yol gösteren, akademik ufkumu açan ve desteğini hiçbir zaman esirgemeyen değerli danışman hocam Prof. Dr. H. Mustafa KANDIRMAZ' a en içten şükranlarımı sunarım.

Çalışmamın yürütülmesi sürecindeki katkıları için Dr. Kazım KABA' ya ayrıca teşekkür etmek isterim.

Veri analizi, model mimarisinin yapılandırılması ve kodlama süreçlerinde yapay zeka asistanı Gemini kullanılmıştır.

Son olarak, akademik çalışmalarımın yoğun temposunda her türlü zorluğa benimle birlikte göğüs geren, sevgisi, sabrı ve sonsuz hoşgörüsüyle bana en büyük güç ve moral kaynağı olan, manevi desteğini bir an olsun esirgemeyen sevgili eşim Rabia YILMAZ' a en derin sevgilerimi ve teşekkürlerimi sunarım.

ÇİZELGELER DİZİNİ

Çizelge 3.1. SEVIRI Spektral Kanalları ve Çözünürlükleri	14
Çizelge 4.1. 17015 Numaralı istasyonun günlük toplam global güneş radyasyon bilgileri	25
Çizelge 4.2. 17351 Numaralı istasyonun günlük toplam global güneş radyasyon bilgileri	26
Çizelge 4.3. 20 istasyona ait tanımlayıcı bilgiler ve coğrafi konumlar	27
Çizelge 4.4. Akçakoca/17015 istasyonuna ait 2023 yılı ocak ayına ait veriler	28
Çizelge 4.5. Akçakoca/17015 istasyonunun 2023 yılı ocak ayı ilk 10 gününe ait Bilinear İnterpolasyon yöntemi ile hesaplanmış bulutluluk indeks değerleri	30
Çizelge 4.6. Akçakoca/17015 istasyonunun 2023 yılı ocak ayı ilk 10 gününe ait En Yakın Komşu yöntemi ile hesaplanmış bulutluluk indeks değerleri	30
Çizelge 4.7. Akçakoca/17015 istasyonunun 2023 yılı ocak ayının ilk 10 gününe ait gün uzunluğu değerleri	31
Çizelge 4.8. Model isimleri ve girdi kombinasyonları	32
Çizelge 4.9. YSA ve bilinear interpolasyon ile eğitilen modellerin sonuçları	33
Çizelge 4.10. YSA ve en yakın komşu ile eğitilen modellerin sonuçları	34
Çizelge 4.11. LightGBM ve bilinear interpolasyon ile eğitilen modellerin sonuçları	38
Çizelge 4.12. LightGBM ve en yakın komşu ile eğitilen modellerin sonuçları	39

ŞEKİLLER DİZİNİ

Şekil 3.1. Klimatolojik rasat parkı	9
Şekil 3.2. Ångström Pirheliyometresi	10
Şekil 3.3. Piyanometre tipleri	11
Şekil 3.4. Robitzch tipi bimetalik Aktinograf	11
Şekil 3.5. Level-2 bulut maskeleri, Level-3 aylık ortalamalar ve bunlara ait belirsizlik haritası	17
Şekil 3.6. SEVIRI'nin mekânsal kapsama alanı ve yerdeki çözünürlüğü	18
Şekil 3.7. Yapay Sinir Hücresi	19
Şekil 3.8. Biyolojik Sinir Hücresi	20
Şekil 3.9. Yapay Sinir Ağı Katmanları	21
Şekil 3.10. ReLu fonksiyonu ve türevi.....	22
Şekil 4.1. Türkiye genelindeki 244 meteorolojik istasyonun coğrafi dağılımı	27
Şekil 4.2. 01 Ocak 2023 gününe ait CFC dosyasının bir kesiti.....	29
Şekil 4.3. 17190 Numaralı istasyonunun M12 model tahmin sonuçları	35
Şekil 4.4. 18455 Numaralı istasyonunun M12 model tahmin sonuçları	36
Şekil 4.5. 17298 Numaralı istasyonunun M12 model tahmin sonuçları	36
Şekil 4.6. 17059 Numaralı istasyonunun M12 model tahmin sonuçları	37
Şekil 4.7. M14 adlı modelin değişken önem analizi	40
Şekil 4.8. 18911 Numaralı istasyonunun M14 model tahmin sonuçları	40
Şekil 4.9. 17190 Numaralı istasyonunun M14 model tahmin sonuçları	41
Şekil 4.10. 17749 Numaralı istasyonunun M14 model tahmin sonuçları	41
Şekil 4.11. 17232 Numaralı istasyonunun M14 model tahmin sonuçları	42

SİMGELER VE KISALTMALAR

ANN (YSA)	: Yapay Sinir Ağları (Artificial Neural Networks)
CFC	: Parçalı Bulut Örtüsü (Fractional Cloud Cover)
CLAAS-3	: CM SAF SEVIRI Tabanlı Bulut Özellikleri Veri Seti - 3. Sürüm
CM SAF	: İklim İzleme Uydu Uygulama Tesis
ECMWF	: Avrupa Orta Vadeli Hava Tahminleri Merkezi
EUMETSAT	: Avrupa Meteoroloji Uyduları İşletme Örgütü
GR	: Güneş Radyasyonu
HRV	: Yüksek Çözünürlüklü Görünür Kanal (High Resolution Visible)
ICDR	: Geçici İklim Veri Kaydı (Interim Climate Data Record)
IR	: Kızılötesi (Infrared)
LightGBM	: Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MGM	: Meteoroloji Genel Müdürlüğü
MSE	: Ortalama Kare Hata (Mean Squared Error)
MSG	: Meteosat İkinci Nesil (Meteosat Second Generation)
n	: 1 Ocaktan itibaren gün sayısı
N	: Belirli bir tarih ve konum için maksimum gün uzunluğu
NIR	: Yakın Kızılötesi (Near Infrared)
R ²	: Belirleme Katsayısı
ReLU	: Doğrusal Düzenlenmiş Birim (Rectified Linear Unit)
RMSE	: Hata Kareler Ortalamasının Karekökü (Root Mean Square Error)
SEVIRI	: Dönen Geliştirilmiş Görünür ve Kızılötesi Görüntüleyici
VIS	: Görünür Spektral Kanal (Visible)
WMO	: Dünya Meteoroloji Örgütü
Ws	: Gün batımı saat açısı
δ (delta)	: Güneş Deklinasyon Açısı
Φ (phi)	: Enlem açısı
$\bar{E}$	: Tahmin edilen değerlerin aritmetik ortalaması
E_i	: Model tarafından tahmin edilen güneş radyasyonu değeri
$\bar{O}$	: Ölçülen değerlerin aritmetik ortalaması
O_i	: Yer istasyonunda ölçülen gerçek güneş radyasyonu değeri

1. GİRİŞ

Enerji, modern toplumların ekonomik ve teknolojik gelişiminin sürdürülebilirliği için temel bileşenlerden biri olarak nitelendirilmektedir. Sanayi Devrimi'nden günümüze kadar olan süreçte enerji ihtiyacı; artan dünya nüfusu ve dijitalleşen yaşam standartlarıyla birlikte sürekli bir artış eğilimi sergilemiştir. Doğal kaynakların korunması ve çevresel değerlerin önem kazanmasıyla birlikte, enerji üretiminde sürdürülebilir yöntemlerin benimsenmesi gündeme gelmiştir. Bu durum, yerli ve çevre dostu enerji teknolojilerine olan yönelimin küresel bir öncelik olarak değerlendirilmesine yol açmıştır.

Yenilenebilir enerji kaynakları; sürekli döngüye sahip, karbon yoğunluğu düşük ve tükenmez özellikleri nedeniyle modern enerji dönüşüm süreçlerinde merkezi bir rol oynamaktadır. Bu kaynaklar içerisinde güneş enerjisi; modüler yapısı, maliyet etkinliği ve geniş uygulama yelpazesiyle ön plana çıkmaktadır. Türkiye, coğrafi konumu gereği Akdeniz kuşağında yer alması sebebiyle yüksek güneş radyasyonu değerlerine ve uzun güneşlenme sürelerine sahip bir ülke konumundadır. Bu iklimsel özelliklerin, ülkenin yenilenebilir enerji kapasitesinin geliştirilmesine yönelik önemli bir potansiyel sunduğu ve bu alandaki akademik faaliyetlerin temel odak noktalarından birini oluşturduğu değerlendirilmektedir.

Güneş enerjisi projelerinin planlanması ve üretilen enerjinin şebeke yönetimi süreçlerine entegrasyonu, yüzeye gelen günlük Güneş Radyasyonu (GR) verilerinin hassasiyetine dayanmaktadır. Mevcut durumda bu veriler genellikle yer istasyonlarındaki piranometreler aracılığıyla elde edilmektedir. Ancak, bu tür hassas ölçüm cihazlarının yüksek kurulum maliyetleri, periyodik kalibrasyon gereksinimleri ve operasyonel bakım süreçleri, geniş bir ölçüm ağı oluşturulmasını güçleştirmektedir. Ayrıca teknik arızalar veya istasyonların coğrafi dağılımındaki kısıtlar nedeniyle veri setlerinde boşluklar oluşabilmektedir.

Yüzeye ulaşan güneş radyasyonu miktarı üzerinde en belirgin etkiye sahip olan atmosferik parametrenin bulutluluk olduğu bilinmektedir. Bulut tabakasının yoğunluğu ve yapısı, radyasyonun atmosferdeki saçılma ve soğurulma süreçlerini doğrudan etkileyerek yer seviyesindeki enerji miktarında değişkenliğe yol açmaktadır. Bulutluluk İndeksi, gökyüzünün bulutlarla kaplı olma durumunu ve bu bulutların güneş radyasyonunu engelleme kapasitesini sayısal olarak ifade eden bir değerdir. Bu nedenle, yer gözlem istasyonlarının bulunmadığı alanlarda radyasyon tahmininin yapılabilmesi için bulutluluk verilerinin takibi önem arz etmektedir. Söz konusu kısıtlar ve fiziksel değişkenler, yer gözlem verilerini destekleyebilecek alternatif ve maliyet etkin yöntemlerin araştırılmasına zemin hazırlamaktadır.

Yer gözlem istasyonlarının kısıtlarını aşmak amacıyla uydu teknolojileri ve modern veri işleme yöntemlerinden faydalanılmaktadır. MSG/SEVIRI gibi uydulardan elde edilen bulutluluk indeksi verileri, geniş coğrafi alanlar için eş zamanlı veri sağlama kapasitesiyle ön plana çıkmaktadır. Son dönemlerde yapılan çalışmalar bu verilerin Yapay Sinir Ağları ve gradyan artırma

tabanlı LightGBM gibi algoritmalarla analiz edilmesi, güneş radyasyonunun yüksek doğrulukla tahmin edilmesine olanak tanımaktadır. Bu tür yaklaşımların, geleneksel yöntemlere kıyasla daha başarılı sonuçlar verdiği gözlemlenmektedir.

Bu çalışmanın temel amacını; uydu kaynaklı bulutluluk indeksi (Cloud Cover Index) verileri kullanılarak Türkiye geneli için günlük güneş radyasyonu tahmin modelinin geliştirilmesi oluşturmaktadır. Çalışma kapsamında, Türkiye genelinde geniş bir coğrafi dağılım sergileyen 244 istasyondan elde edilen 2023-2024 yıllarına ait günlük güneş radyasyonu verileri kullanılmıştır. Geliştirilen tahmin modellerinin performansı; R^2 , RMSE ve MAE gibi istatistiksel metrikler aracılığıyla değerlendirilmiştir. Bu çalışmada uydu verilerinin mekânsal ve zamansal avantajları ile modern algoritmaların tahmin gücünün birleştirilmesi amaçlanmıştır. Bu doğrultuda, Türkiye'nin güneş enerjisi potansiyelinin belirlenmesine ve enerji yönetim süreçlerine katkı sağlanması hedeflenmektedir.



2. ÖNCEKİ ÇALIŞMALAR

GR, yeryüzündeki enerji dengesinin temel sürdürücüsü olup hidrolojik döngüden enerji üretimine, tarımsal verimlilikten iklim değişikliği izleme çalışmalarına kadar pek çok alanda kritik bir veri olarak kullanılmaktadır. Güneş enerjisi sistemlerinin planlanması, maliyet analizleri ve işletme süreçleri için yeryüzüne ulaşan radyasyon miktarının yüksek doğrulukla bilinmesi gerekmektedir. Günümüzde bu veriler yer istasyonlarındaki piranometreler aracılığıyla hassas bir şekilde ölçülmektedir. Ancak ölçüm istasyonlarının kurulum ve işletme maliyetlerinin yüksek olması, periyodik kalibrasyon ihtiyaçları ve yersel olarak kısıtlı bir alanı temsil etmeleri, geniş bölgeler için kesintisiz veri elde edilmesini zorlaştırmaktadır. İstasyon bulunmayan bölgelerde güneş radyasyonu değerleri genellikle tahmin modelleriyle belirlenmektedir.

Atmosferden geçerek yeryüzüne ulaşan güneş ışınımını etkileyen ve zayıflatan en temel faktör bulutluluk durumudur. Bulutların radyasyon üzerindeki bu engelleyici etkisi nedeniyle araştırmacılar, uydulardan elde edilen bulutluluk indeksi parametresini güneş radyasyonu tahminlerinde temel bir girdi olarak ele almışlardır. Meteorolojik uydular, geniş alanları yüksek zamansal ve mekânsal çözünürlükle sürekli olarak izleyebildikleri için yer ölçüm ağlarındaki boşlukları doldurmak adına en etkili araç haline gelmiştir. Uydudan alınan sayısal görüntü değerlerinin bulut ve açık gökyüzü koşullarına göre normalize edilmesiyle elde edilen bulutluluk indeksi, radyasyonun atmosferdeki zayıflama oranını belirlemek için yaygın olarak kullanılmaktadır.

GR tahminine yönelik literatürdeki yaklaşımlar zaman içerisinde evrilmiştir. İlk dönem çalışmalarında uydu verileri ile yer ölçümleri arasında istatistiksel ilişkiler kuran ampirik modeller ve atmosferik transfer süreçlerini açıklayan fiziksel yöntemler ağırlık kazanmıştır. Ancak atmosferik olayların karmaşık ve değişken yapısı, araştırmacıları daha gelişmiş tekniklere yöneltmiştir. Son yıllarda YSA, destek vektör makineleri ve rastgele orman gibi makine öğrenmesi algoritmaları, radyasyonun doğrusal olmayan davranışlarını modellemede başarılı sonuçlar vermiştir.

Öte yandan bazı araştırmacılar meteorolojik uydu görüntüleri kullanarak küresel güneş radyasyonunu belirlemek için istatistiksel bir yöntem sunmuşlardır. Çalışmada, uydu görüntülerinden elde edilen bulutluluk indeksi ile yer ölçümleri arasında doğrusal bir ilişki kurmuşlardır. Bu yaklaşımın, ölçüm istasyonu olmayan bölgelerde radyasyon haritalama ve mezoklimatik değişimleri izlemek için etkili bir araç olduğunu vurgulamışlardır (Cano ve ark., 1986, Kandırmaz ve ark., 2004).

Mefti ve ark (2008) Meteosat görüntülerini kullanarak saatlik küresel güneş radyasyonunu tahmin etmek için SICIC (Bulut Görüntü Sınıflandırmasından Güneş Işınımı) adlı yeni bir model geliştirmişlerdir. Bulutluluk indekslerini iki ayarlanabilir eşik değeri kullanarak açık, parçalı bulutlu

ve kapalı gökyüzü şeklinde üç sınıfa ayırmışlardır. Güneş yükselme açısını modele dâhil ederek, özellikle düşük güneş açılarında tahmin hatalarının önemli ölçüde azaldığını rapor etmişlerdir.

Şenkal ve Kuleli (2009) Türkiye üzerindeki 12 şehir için güneş radyasyonunu fiziksel yöntem ve YSA kullanarak tahmin etmişlerdir. Meteosat-6 uydu verilerinden elde edilen bulutluluk indeksi ile birlikte enlem, boylam ve ay gibi coğrafi/meteorolojik verileri YSA modeline girdi olarak tanımlamışlardır. YSA modellerinin fiziksel yöntemlere kıyasla daha düşük hata oranları sunduğunu ve radyasyon veri tabanı oluşturmak için ekonomik bir çözüm olduğunu belirtmişlerdir.

Yang ve ark (2012) Bulutluluk indeksi etkilerini dâhil ederek saatlik güneş ışıınımı tahmini için zaman serisi analizi uygulamışlardır. ARIMA modellerini kullanarak bulut geçişlerini tahmin etmiş ve farklı bulutluluk koşulları ile zenit açıları için bir regresyon "bak-bul" (look-up) tablosu oluşturmuşlardır. Bulutluluk bilgisinin dâhil edilmesinin, geleneksel ARIMA modellerine göre tahmin doğruluğunu artırdığını kanıtlamışlardır.

Shamim ve ark (2015) Sadece uydulardan değil, aynı zamanda MM5 sayısal hava tahmin modelinden elde edilen verilerle hibrit bir güneş radyasyonu tahmin tekniği geliştirmişlerdir. Atmosferdeki basınç ve nem verilerinden bir bulutluluk indeksi türeterek bulutların radyasyon üzerindeki zayıflatma etkisini parametreleştirmişlerdir. Bu hibrit yaklaşımın, yer gözlemlerinin yetersiz olduğu havzalarda yüksek doğrulukta sonuçlar verdiğini göstermişlerdir.

Ener Ruşen (2017) Türkiye'nin enerji ihtisas bölgesi olan Karaman ili için küresel güneş radyasyonu potansiyelini Heliosat metodu ile belirlemiştir. Meteosat-8 uydusundan alınan 3 yıllık verileri işleyerek bulut ve açık gökyüzü indekslerini hesaplamış; elde edilen sonuçları yer ölçümleriyle karşılaştırmıştır. Uydu tabanlı tahminlerin yer verileriyle yüksek korelasyon gösterdiğini ve bölgenin güneş enerjisi planlaması için güvenilir veriler sunduğunu tespit etmiştir.

Yakoubi ve ark (2021) Fas'taki 14 şehir için bulutluluk indeksi ile diğer meteorolojik parametreleri birleştiren 17 yeni ampirik regresyon modeli önermişlerdir. Bulut kapallılığının radyasyonu engelleyen en önemli faktör olduğunu vurgulayarak; modele sıcaklık, nem ve rüzgar hızı eklendiğinde tahmin performansının belirgin şekilde iyileştiğini rapor etmişlerdir. Bu modellerin piranometre ölçümü olmayan bölgeler için uygun maliyetli bir alternatif olduğunu belirtmişlerdir.

Küçüktopçu ve ark (2024) Türkiye'nin Kütahya ili için KNN, SVR ve Rastgele Orman modellerini dalgacık dönüşümü ile birleştirerek günlük güneş radyasyonu tahmini gerçekleştirmişlerdir. Bulutluluk ve güneşlenme süresinin radyasyon üzerindeki etkisini incelemiş, hibrit SVR-WT modelinin en yüksek doğruluğu (R^2 : 0,92) verdiğini saptamışlardır. Çalışma, dalgacık dönüşümü entegrasyonunun makine öğrenmesi modellerinin başarısını artırdığını ortaya koymuştur.

Kandırılmaz ve Kaba (2014) polar yörüngeli Aqua ve Terra uydularındaki MODIS sensörlerini kullanarak Türkiye için günlük güneşlenme süresini tahmin etmişlerdir. Günlük ortalama bulutluluk indeksi ile bağıl güneşlenme süresi arasında yeni bir kuadratik korelasyon

önermişler; bu modelin, özellikle yer istasyonlarında çok düşük güneşlenme değerlerinin kaydedildiği kış aylarında doğrusal modellerden daha iyi sonuç verdiğini saptamışlardır.

Kaba (2012) MODIS uydu verilerini kullanarak Türkiye genelinde 250m x 250m çözünürlüğünde pikseller için bulutluluk indeksi oluşturmuştur. Bu indeks yardımıyla günlük ve aylık güneşlenme süresini hesaplamış ve uydu tabanlı tahminlerin, ölçüm istasyonu bulunmayan bölgelerde kabul edilebilir hata payları ile kullanılabileceğini kanıtlamıştır.

Shamim ve ark (2015) MM5 sayısal hava tahmin modelinden elde edilen üst atmosfer verilerini (nem ve basınç) kullanarak küresel güneş radyasyonu tahmini için iyileştirilmiş bir teknik geliştirmişlerdir. Atmosferi dört tabakaya ayırarak bağıl nem verilerinden bir bulutluluk indeksi türetmişler ve bu hibrit yaklaşımın yer gözlemlerinin yetersiz olduğu havzalarda piranometre ölçümleriyle yüksek korelasyon sağladığını rapor etmişlerdir.

Dong ve ark (2014) Tropikal bölgeler için uydu görüntüsü analizi ile ESSS (Üstel Düzeltme Durum Uzayı) ve Yapay Sinir Ağlarını birleştiren hibrit bir model önermişlerdir. Bulut oluşumunun stokastik doğası nedeniyle, bulutluluk indeksi bilgilerinin bu hibrit modellerle işlenmesinin, karmaşık atmosferik koşullarda güneş ışıınımı tahmin başarısını artırdığını ifade etmişlerdir.

Ordoñez Palacios ve ark (2023) uydu görüntüleri ve meteorolojik verileri entegre ederek güneş radyasyonunu tahmin etmek için XGBoost, Random Forest ve YSA gibi regresyon yöntemlerini değerlendirmişlerdir. Veri entegrasyonu yapılan senaryolarda sinir ağlarının en yüksek performansı sergilediğini, ancak topluluk (ensemble) temelli karar ağacı yöntemlerinin de (XGBoost vb.) yüksek doğruluk ve düşük hata oranları sağladığını saptamışlardır.

Atmosferik olayların karmaşık ve değişken yapısı nedeniyle, ampirik modellerden daha çok radyasyonun doğrusal olmayan davranışlarını modellemede başarılı sonuçlar veren YSA ve destek vektör makineleri gibi makine öğrenimi teknikleri ön plana çıkmıştır. Türkiye özelinde yapılan çalışmalarda YSA modellerinin geleneksel yöntemlere göre daha düşük hata oranları sunduğu rapor edilmiş olsa da, literatürde Gradyan Artırma Makineleri (GBM) gibi topluluk öğrenme algoritmalarının özellikle büyük veri setlerini işleme hızı ve tahmin doğruluğu açısından sunduğu potansiyel henüz tam olarak keşfedilmemiştir. Bu tez çalışmasında, başarısı kanıtlanmış olan YSA yönteminin yanı sıra karar ağaçlarının modern ve verimli bir sürümü olan LightGBM algoritması kullanılmıştır. Uydudan elde edilen günlük bulutluluk indeksleri üzerinden bu iki yöntemin karşılaştırmalı performans analizlerinin yapılması hedeflenerek, operasyonel hız ve doğruluk açısından literatürdeki mevcut boşluğun doldurulması amaçlanmıştır.



3. MATERYAL VE METOT

3.1. Materyal

Çalışma dönemi 2023 ile 2024 yılları arasını kapsamaktadır. Bu zaman aralığının belirlenmesinde, uydu tabanlı güncel bulutluluk verileri ile yer gözlem istasyon kayıtlarının eş zamanlı mevcudiyeti esas alınmıştır. Çalışmada kullanılan temel veri setleri aşağıda sunulmuştur:

- Yer Gözlem Verileri: Meteoroloji Genel Müdürlüğü tarafından Türkiye genelinde geniş bir coğrafi dağılım sergileyen 244 istasyonda ölçülen günlük toplam güneş radyasyonu verileri kullanılmıştır.
- Uydu Veri Seti: EUMETSAT bünyesindeki İklim İzleme Uydu Uygulama Tesisi (CM SAF) tarafından sağlanan "CLAAS-3: CM SAF CLOUD property dAtAset using SEVIRI – Edition 3" veri seti kullanılmıştır. Bu veri seti, Meteosat İkinci Nesil (MSG) uyduları üzerindeki SEVIRI sensöründen elde edilen bulut özelliklerini içermektedir. Çalışmada, bulutluluk indeksinin günlük ortalama değerleri temsil eden "Fractional Cloud Cover (CFC)" ürünü temel girdi olarak tercih edilmiştir.
- Coğrafi Veriler: İstasyonlara ait enlem, boylam, gün uzunluğu ve zamansal (ay ve yılın günü) bilgilerini içeren coğrafi verilerden faydalanılmıştır.

Söz konusu verilerin indirilmesi, ön işlemesi ve modelleme süreçlerinde kullanılan donanım ve yazılım altyapısı aşağıda belirtilmiştir:

Donanım Özellikleri:

- Intel i7 işlemciye sahip, 32 GB RAM ve 1 TB depolama kapasitesi bulunan Windows 11 tabanlı iş istasyonu kullanılmıştır.

Yazılım ve Programlama Araçları:

- Anaconda: Python tabanlı bilimsel hesaplamalar ve veri yönetimi süreçlerinde açık kaynaklı dağıtım ve paket yönetim sistemi olarak tercih edilmiştir.
- Spyder: Algoritma geliştirme, veri analizi ve modelleme aşamalarında entegre geliştirme ortamı (IDE) olarak kullanılmıştır.
- MySQL Workbench 8.0 CE: Araştırma kapsamında kullanılan büyük ölçekli veri setlerinin yapılandırılması, depolanması ve sorgulanması süreçlerinde ilişkisel veri tabanı yönetim sistemi olarak kullanılmıştır.

- Microsoft Office Excel: Verilerin ön düzenleme süreçlerinde ve elde edilen sonuçların tablolaştırılması aşamalarında kullanılmıştır.

3.1.1. Yer Ölçümleri

Sıcaklık, basınç, rüzgâr, nem, yağış ve güneşlenme gibi iklim elemanlarının ölçümlerinin düzenli olarak yapıp kayıt altına alınması işlemine rasat denilmektedir. Atmosfer olaylarına açık olan, hava olaylarını engelleyici unsurlardan arındırılmış ve içerisinde çeşitli meteorolojik ölçüm aletlerinin bulunduğu doğal şartları temsil eden düzenlenmiş alanlar ise rasat parkı olarak tanımlanmaktadır.

Meteorolojide kullanım amaçlarına göre sinoptik, havacılık, yüksek hava (radiosonde) ve klimatolojik gözlemler gibi farklı rasat türleri icra edilmektedir. Klimatolojik rasatların temel hedefi; kıtaların, ülkelerin veya daha dar bölgelerin iklim durumlarını incelemek, bilimsel araştırmalar yürütmek ve tarım, enerji, ulaşım gibi çeşitli sektörlerin projeleri için gerekli temel veri setlerini oluşturmaktır.

Meteorolojik gözlemler; çoğulukla anlık değişimleri diyagramlara kaydeden yazıcı cihazlar ve otomatik kayıt yapabilen yüksek teknolojiyle donatılmış ve cihazlar aracılığıyla gerçekleştirilmektedir. Türkiye’de klimatolojik rasatlar, mahallî saatle 07:00, 14:00 ve 21:00 vakitlerinde yapılmaktadır. Bu saatlerin tercih edilme gerekçesi, bu vakitlerde yapılan üç rasadın ortalamasının, günün 24 saatlik gerçek ortalama değerlerine en yakın sonucu vermesidir.

Rasat parkları kare formunda inşa edilmekte ve kenarları dört ana yöne paralel olacak şekilde konumlandırılmaktadır. Parkın giriş kapısı ve içeride bulunan alet siperlerinin kapıları, ölçüm anında güneş ışınlarının cihazlar üzerine doğrudan düşerek hatalı sonuçlar vermesini engellemek amacıyla kuzey yönüne bakacak şekilde yerleştirilmektedir. Alanın çevresi, ölçüm cihazlarını dış müdahalelerden korumak amacıyla yaklaşık 110 cm yüksekliğinde tel örgülerle çevrilmektedir (Şekil 3.1). Bu örgüler, güneş radyasyonunu emmemesi ve dayanıklı olması için beyaz boya ile boyanmaktadır. Park boyutları kullanım amacına göre 3x3 m ile 20x20 m arasında değişmektedir. İstasyonun kurulacağı sahanın seçiminde, çevre engellerin ölçüm noktasına bu engellerin yüksekliğinin en az 10 katı kadar uzakta olması temel şart olarak kabul edilmektedir. (MGM, 2026)



Şekil 3.1. Klimatolojik rasat parkı (MGM, 2026)

Güneş Radyasyonu

Yeryüzünü ve atmosferi ısıtan en temel ve baskın enerji kaynağı güneştir. Bütün canlıların yaşam döngüsü ve meteorolojik olayların gelişimi, doğrudan veya dolaylı olarak bu enerjiye dayalıdır. Bitkilerin fotosentez yapabilmesi, gıda üretimi ve biyolojik hayatın sürekliliği güneşten gelen radyasyon enerjisi ile mümkün olmaktadır. Kömür, petrol ve odun gibi yakıtlar esasen depo edilmiş güneş enerjisi olarak kabul edilmektedir. Güneş radyasyonu karaların ve denizlerin ısınmasını sağlayarak buharlaşma, yağış, rüzgâr ve deniz akıntılarının oluşmasına neden olan temel etkindir. İklimi meydana getiren temel atmosfer özelliklerinden biridir. Yeryüzündeki sıcaklık dağılımı ve basınç farkları güneşlenme şiddetine bağlı olarak şekillenmektedir. Güneş radyasyonu, güneş tarafından yayılan, iletilen veya alınan elektromanyetik enerji olarak tanımlanmaktadır. Güneşten gelen enerjinin %99'luk bir kısmı kısa dalga boylarından oluşmaktadır.

Dünyanın güneşe ortalama uzaklıkta bulunduğu varsayıldığında, dünya atmosferinin dış sınırındaki birim yüzeye, birim zamanda dik olarak gelen radyasyon miktarına güneş sabiti denilmektedir. Bu değer bilimsel kaynaklarda $1,94 \pm 0,04 \text{ cal/cm}^2.\text{dakika}$ olarak kabul edilmektedir.

Yeryüzüne ulaşan güneş enerjisi fiziksel yapısı itibarıyla üç bileşenden oluşmaktadır:

- Direkt Radyasyon: Herhangi bir yansıma veya dağılmaya uğramadan doğrudan yere ulaşan ışınlardır.
- Difüz (Yayılan) Radyasyon: Bulut veya diğer yayıcı ortamlardan geçerken dağılarak yeryüzüne ulaşan radyasyondur.

- Küresel (Global) Radyasyon: Yatay bir yüzey üzerine düşen direkt ve difüz radyasyonun toplamı olarak tanımlanmaktadır.

Bulutlar, güneş radyasyonunun yeryüzüne ulaşmasını engelleyen veya dağıtan en önemli faktörlerden biridir. Atmosfere gelen toplam güneş radyasyonunun yaklaşık %23'ü bulutlar tarafından doğrudan geriye yansıtılmaktadır. Gökyüzündeki bulutluluk oranı ve bulutların yoğunluk derecesi, yere ulaşan radyasyonun şiddetini ve güneşlenme süresini doğrudan azaltmaktadır. (MGM, 2026)

Güneş Radyasyon Ölçümleri

Güneş radyasyonu ölçümlerinde temel standart, Dünya Meteoroloji Örgütü (WMO) tarafından belirlenen kılavuzlara ve uluslararası pirheliyometre ıskalalarına dayanmaktadır. Ölçümlerin doğruluğu için cihazların Ångström Pirheliyometresi gibi standart kabul edilen aletlere göre periyodik olarak kalibre edilmesi zorunludur. Radyasyon sensörleri, her türlü hava şartına dayanıklı olmalı, yatay düzlemleri su terazisi ile hassas şekilde ayarlanmalı ve çevresindeki engellerden arındırılmış bir sahaya monte edilmelidir.


Meteorolojide radyasyonun farklı bileşenlerini ölçmek için çeşitli cihazlar kullanılmaktadır:

- Pirheliyometre (Pyrheliometer): Yalnızca güneşten gelen direkt radyasyonu ölçmek amacıyla tasarlanmıştır. Cihazın alıcı yüzeyi, güneş ışınlarına daima dik gelecek şekilde ayarlanır. Diyaframlar vasıtasıyla sadece güneş diski ve yakın çevresinden gelen ışınlar ölçüme dâhil edilir (Şekil 3.2).



Şekil 3.2. Ångström Pirheliyometresi (MGM, 2026)

- Piyanometre (Pyranometer): Güneş ve gökyüzünden yatay bir yüzeye düşen toplam küresel radyasyonu ölçer. Cam bir fanus içindeki hassas sensörler aracılığıyla 300 nm ile 3000 nm aralığındaki enerji miktarını tespit eder (Şekil 3.3).



Şekil 3.3. Piyanometre tipleri (MGM, 2026)

- Aktinograf (Robitzsch Tipi): Güneşlenme şiddetini mekanik olarak kaydeden bir cihazdır. Çalışma prensibi, güneş radyasyonuna maruz kalan siyah bir bimetalik çubuk ile radyasyondan korunan beyaz bimetalik çubuklar arasındaki sıcaklık farkına dayanır. Bu fark, mekanik bir kol aracılığıyla döner silindir üzerindeki diyagrama $\text{cal/cm}^2.\text{dak}$ cinsinden aktarılır. Meteoroloji Genel Müdürlüğü (MGM) teşkilatında özellikle Robitzsch tipi Fuess bimetal aktinografları yaygın olarak kullanılmaktadır (Şekil 3.4).



Şekil 3.4. Robitzch tipi bimetalik Aktinograf (MGM, 2026)

Büyük klimatoloji istasyonlarında güneşlenme süresi ve radyasyon şiddeti günlük olarak takip edilir. Helyograf diyagramları genellikle güneş battıktan sonra değiştirilir. Her gün

güneşlenme olsun veya olmasın, tozdan arındırılmış yeni bir diyagramın takılması şarttır. Aktinograf kayıtları ise 24 saatlik süre boyunca sürekli olarak diyagram üzerine işlenir.

Radyasyon şiddeti, Aktinograf diyagramındaki eğrinin altında kalan alan hesaplanır. Düzgün eğrilerde en yüksek ve en düşük iki noktanın ortalaması alınırken; titreşimli (bulutlu) kayıtlarda beş farklı noktanın ortalaması alınarak saatlik toplam kalori miktarı bulunur. Elde edilen saatlik değerler toplanarak günlük cal/cm^2 toplamı elde edilir. (MGM, 2026)

Radyasyon ölçümlerinde verilerin doğruluğunu etkileyen temel faktörler şunlardır:

- Çevresel Engeller: Bina veya ağaç gibi objelerin ufuktan 3 dereceden fazla yükseklikte bulunması, özellikle doğuş ve batış anlarında eksik ölçüme neden olur.
- Kirlilik ve Nem: Cam küre veya piyanometre fanusu üzerindeki toz, çiy, kar veya kırağı ışık geçirgenliğini azaltarak hatalı sonuçlar doğurur.
- Kurulum ve Ayar Hataları: Cihazın yatay olmaması, coğrafi kuzey-güney hattına tam paralel yerleştirilmemesi veya enlem ayarının hatalı yapılması kayıtların kaymasına yol açar.
- Mekanik Sorunlar: Aktinograf gibi cihazlarda bimetal sistemin zayıf ışıkta tutukluk yapması ölçüm hassasiyetini düşürür. Bu durum vibratörlerle önlenmeye çalışılır.

3.1.2. Meteorolojik Uydur Verileri

Meteorolojik uydular, atmosferde meydana gelen hava olaylarını ve yeryüzündeki iklim tiplerini uzaktan algılama teknikleriyle inceleyen gözlem araçları olarak tanımlanır. Bu sistemler, atmosferin hem düşey hem de yatay doğrultuda detaylı bir şekilde analiz edilmesine imkân tanır.

Hava tahminlerinin doğruluğunu artırmak ve özellikle şiddetli hava olaylarını erkenden tespit edebilmek için meteorolojide uydur verilerine ihtiyaç duyulur. Yer gözlem istasyonlarının bulunmadığı okyanuslar, çöller ve kutup bölgeleri gibi geniş alanlardan kesintisiz veri toplanması bu araçlarla mümkün kılınmaktadır.

Yer gözlemleri, belirli istasyonlardaki fiziksel ölçüm aletleriyle yapılan doğrudan ve noktasal ölçümlerden oluşur. Meteorolojik uydular ise yer sistemlerinin aksine küresel ölçekte, sürekliliği olan ve çok daha geniş alanları kapsayan veriler sunan uzaktan algılama sistemleridir (MGM, 2026).

Meteorolojik uyduların temel işlevi; atmosfer, okyanus ve kara yüzeylerini izlemek, bulut oluşumlarını görüntülemek ve bu verileri hava tahmini ile iklim izleme çalışmaları için işlenebilir hale getirmektir. Şiddetli hava olaylarının önceden belirlenerek can ve mal kayıplarının en aza indirilmesi ve küresel iklim değişimlerinin hassasiyetle takip edilmesi açısından büyük önem taşırlar.

Meteorolojik uydular, operasyonel amaçlarına göre iki ana yörüngede sınıflandırılır. Yer'in dönüşüyle eş zamanlı hareket ederek sürekli aynı bölgeyi izleyen sabit yörüngeli uydular ve yer

çevresini kutuplar doğrultusunda dönerek küresel tarama yapan kutupsal yörüngeli uydular meteorolojik gözlemlerde kullanılır.

Sabit yörüngeli uydular yer yüzeyinden yaklaşık 36.000 km yükseklikte bulunan bu uydular, Dünya'ya göre sabit bir konumda kalarak belirli bir bölgeyi kesintisiz gözlemlerler. Özellikle hızlı gelişen fırtınaların takibi ve kısa vadeli hava tahminleri için bu sistemlerden yararlanılır. Meteosat serisi, şiddetli hava olaylarının erken tespiti için kullanılan bu tür uyduların en gelişmiş örneklerindendir.

Kutupsal yörüngeli uydular, yaklaşık 817 km gibi daha düşük bir irtifada görev yaparlar. Dünya çevresindeki bir tam turu yaklaşık 101 dakikada tamamlarlar ve kutuplar doğrultusunda hareket ederek Dünya'nın her noktasından günde birkaç kez geçerler. Atmosfer, okyanus ve kara yüzeylerine ait sağladıkları detaylı veriler, özellikle orta vadeli hava tahmin modelleri ve küresel iklim izleme çalışmaları için kritiktir. Metop serisi bu uydulara örnek olarak gösterilir.

Uydulardan elde edilen küresel atmosferik gözlemler, sayısal hava tahmin modellerinin en önemli bileşenlerini oluşturur. Bu veriler, 10 günlük sürelerle kadar olan hava tahminlerinin tutarlılığını sağlamak amacıyla model girdisi olarak kullanılır.

Küresel iklim sistemindeki değişimlerin belirlenmesinde uydu verileri temel unsurdur. Sıcaklık değişimleri, okyanus durumları ve kara yüzeylerindeki uzun vadeli dönüşümler bu veriler ışığında izlenir. (EUMETSAT, 2026a)

Meteoroloji Genel Müdürlüğü, operasyonel hava tahmini ve meteorolojik araştırmalar kapsamında Meteosat uydularından gelen görüntüleri aktif olarak kullanmaktadır.

3.1.3. EUMETSAT ve Meteosat Uyduları

Avrupa Meteoroloji Uyduları İşletme Teşkilatı (EUMETSAT), Avrupa'nın yer durağan ve kutupsal yörüngeli meteorolojik uydu sistemlerini işletmek amacıyla kurulmuş hükümetler arası bir kuruluştur. Kuruluşun temel görevi, üye devletlerin ve uluslararası kullanıcıların ihtiyaçları doğrultusunda hava durumu, iklim ve çevre hakkında kesintisiz, doğru ve güvenilir uydu verileri sağlamaktır. Avrupa meteorolojik uydu verilerinin alımı, işlenmesi, dağıtımı ve arşivlenmesi süreçleri doğrudan EUMETSAT sorumluluğundadır.

Meteosat programı, Avrupa'nın meteorolojik gözlem kapasitesini geliştirmek amacıyla üç nesil üzerinden evrimleşmiştir.

Birinci nesil (MFG), 1977 yılında fırlatılan Meteosat-1 ile başlamış olup, MVIRI görüntüleyicisi ile üç kanalda veri toplamıştır. Bu nesilde tam disk taraması her 30 dakikada bir gerçekleştirilmiştir (EUMETSAT, 2026b).

İkinci nesil (MSG), 2002 yılındaki fırlatma ile devreye girmiş; 12 spektral kanala sahip SEVIRI radyometresi ile tarama sıklığı 15 dakikaya indirilmiştir. MSG uyduları dünyanın tam disk görüntüsünü her 15 dakikada bir sağlamaktadır (ECMWF, 2026).

Üçüncü nesil (MTG) ise görüntüleyici (MTG-I) ve sondaj (MTG-S) uydularından oluşan bir takımla en gelişmiş gözlem imkânlarını sunmaktadır. MTG nesli ile tam disk tarama süresi 10 dakikaya indirilmiştir (EUMETSAT, 2026b).

MSG uyduları tarafından üretilen Seviye 1.0 ham verileri, işlenmek üzere EUMETSAT'ın Darmstadt'taki merkezine aktarılmaktadır. Veri işleme zinciri; veri alımı, ön işleme, radyometrik ve geometrik düzeltmeler ile meteorolojik ürün üretimi ve dağıtımı safhalarını içermektedir. Bu süreçte ham veriler, Seviye 1.5 formatına dönüştürülerek coğrafi tescil işlemleri tamamlanmakta ve standart bir projeksiyon düzlemine yerleştirilmektedir. Elde edilen Seviye 1.5 verileri, Meteorolojik Ürün Çıkarma Tesisi bünyesinde Seviye 2.0 meteorolojik ürünlerinin üretiminde temel girdi olarak kullanılmaktadır. 15 dakikalık görüntüleme sıklığı ile hazırlanan bu çıktılar, şimdi-tahmin (nowcasting) uygulamaları için kritik bir kaynak teşkil etmektedir. (ECMWF, 2026).

MSG uydularının ana pay yükü olan SEVIRI radyometresi, 12 farklı spektral kanalda sürekli dünya gözlemi yapmaktadır. Cihaz bünyesinde yer alan kanalların 11 tanesi 3 km mekânsal örnekleme mesafesine sahipken, Yüksek Çözünürlüklü Görünür (HRV) kanalı 1 km örnekleme mesafesi ile veri toplamaktadır. HRV kanalı, Doğu-Batı yönünde tam diskin yarısını kapsayacak bir görüş alanına sahip olup görüntüleme bölgesi kullanıcı gereksinimlerine göre seçilebilmektedir. SEVIRI'nin 15 dakikalık tam disk tarama döngüsü, özellikle şiddetli konveksiyon gibi hızla değişen atmosferik olayların yüksek zamansal çözünürlükle izlenmesine imkân tanımaktadır. (ECMWF, 2026).

Çizelge 3.1. SEVIRI Spektral Kanalları ve Çözünürlükleri (ECMWF, 2026)

Kanal No	Kanal Adı	Merkez Dalga Boyu	Mekansal Çözünürlük	Zamansal Çözünürlük
1	VIS 0.6	0.635	3 km	15 Dakika
2	VIS 0.8	0.81	3 km	15 Dakika
3	NIR 1.6	1.64	3 km	15 Dakika
4	IR 3.9	3.90	3 km	15 Dakika
5	WV 6.2	6.25	3 km	15 Dakika
6	WV 7.3	7.35	3 km	15 Dakika
7	IR 8.7	8.70	3 km	15 Dakika
8	IR 9.7	9.66	3 km	15 Dakika
9	IR 10.8	10.80	3 km	15 Dakika
10	IR 12.0	12.00	3 km	15 Dakika
11	IR 13.4	13.40	3 km	15 Dakika
12	HRV	Geniş Bant	1 km	15 Dakika

Spektral Kanalların Meteorolojik Kullanımı

Spektral kanallar atmosferin ve yer yüzeyinin farklı özelliklerini izlemek için optimize edilmiştir (ECMWF, 2026):

- VIS 0.6 ve 0.8: Bulut tespiti, bulut takibi, sahne tanımlama ve bitki örtüsü izlemede kullanılmaktadır.
- NIR 1.6: Kar ve bulut ayrımı ile buz bulutlarının tespiti için radyometrik bilgi sağlar.
- IR 3.9: Gece sisi ve alçak bulut tespiti ile deniz/kara yüzey sıcaklığı ölçümünde işlevseldir.
- WV 6.2 ve 7.3: Troposferin farklı katmanlarındaki su buharı dağılımı ve rüzgâr vektörlerinin belirlenmesini sağlar.
- IR 8.7: İnce sirüs bulutları üzerinde kantitatif bilgi ve buz/su bulutu ayrımı sağlar.
- IR 9.7: Ozon radyasları aracılığıyla toplam ozon miktarının takibinde kullanılır.
- IR 10.8 ve 12.0: Deniz ve kara yüzey sıcaklıkları ile bulut tepe sıcaklıklarının ölçümünde temeldir.
- IR 13.4: Sirüs bulutlarının yükseklik ataması ve atmosferik kararsızlık analizlerinde kullanılmaktadır.

MSG Ürün Türleri

MSG verilerinden türetilen meteorolojik ürünler, Meteorolojik Ürün Çıkarma Tesisi (MPEF) tarafından üretilmektedir (ECMWF, 2026).

- Bulut Analizi (CLA): Bulut kapallılığı, sıcaklığı, yüksekliği, tipi ve fazı hakkında parametreler sunar.
- Atmosferik Hareket Vektörleri (AMV): Sayısal hava tahmini için bulut ve su buharı hareketlerinden türetilen rüzgâr verileridir.
- Bulut Tepe Yüksekliği (CTH): Havacılık meteorolojisi için yüksek çözünürlüklü bulut yüksekliği bilgisi sağlar.
- Troposferik Nem (TH): Üst ve orta troposferdeki bağıl nem tahminlerini içerir.
- Küresel Kararsızlık İndeksi (GII): Atmosferik kararlılığı izlemek için kullanılan bir hava kütlesi parametresidir.
- Toplam Ozon (TOZ): 9.7 µm kanalı yardımıyla toplam ozon miktarını takip eder.
- İklim Veri Setleri (CDS): Uzun süreli klimatolojik çalışmalar için arşivlenen istatistiksel veri setleridir.


3.1.4. CM SAF CLAAS-3 Parçalı Bulut Örtüsü (CFC) Ürünü

EUMETSAT üye devletleri tarafından 2000 yılında gerçekleştirilen sözleşme değişikliği ile kurumun yetki alanı operasyonel iklim izleme ve küresel iklim değişikliklerinin tespiti konularını kapsayacak şekilde genişletilmiştir. Bu doğrultuda, Uydu Uygulama Tesisleri (SAF) ağı içerisinde iklim izleme süreçlerine odaklanan İklim İzleme SAF (CM SAF) merkezi kurulmuştur. CM SAF, temel iklim veri kayıtlarının kalitesini artırmak ve Küresel İklim Gözlem Sistemi (GCOS) tarafından tanımlanan Temel İklim Değişkenlerini (ECV) üretmekle görevlendirilmiştir (CMSAF, 2026a).

Uydu tabanlı meteorolojik ürünler, özellikle küresel enerji ve su döngüsü ile ilişkili iklim değişkenlerinin uzun vadeli analizinde kritik bir rol oynamaktadır. CM SAF, araştırma kuruluşları tarafından gerçekleştirilen veri seti değerlendirme süreçlerine katılarak uluslararası standartlarda veri üretimi sağlamaktadır. Üretilen bu veriler, olgunlaşmış araştırma ürünlerinin operasyonel ortamlara taşınması ve sürdürülebilir bir altyapı üzerinden kullanıcılara sunulması amacıyla geliştirilmektedir (CMSAF, 2026b).

CLAAS-3 veri seti, MSG uyduları üzerinde bulunan SEVIRI sensöründen elde edilen 12 spektral kanal verisi kullanılarak oluşturulmaktadır. Veri seti, 2004-2020 dönemini kapsayan bir Tematik İklim Veri Kaydı (TCDR) ile 2021 yılından günümüze kadar düşük gecikme süresiyle uzatılan Geçici İklim Veri Kaydı (ICDR) bileşenlerinden meydana gelmektedir (CMSAF, 2026a).


Parçalı Bulut Örtüsü (CFC - Fractional Cloud Cover), belirli bir ızgara hücresi içerisindeki bulutlu piksellerin toplam piksellere oranı olarak tanımlanmakta ve yüzde (%) cinsinden ifade edilmektedir. Ürün, bölgesel ve büyük ölçekli bulut süreçlerinin çeyrek saatlik (15 dakika) seviyeden yıllık ölçeklere kadar incelenmesine imkân tanımaktadır. Şekil 3.5' de görüldüğü üzere, ürün içeriğinde anlık Level-2 bulut maskelerinin yanı sıra Level-3 aylık ortalamalar ve bunlara ait belirsizlik haritaları sunulmaktadır (CMSAF, 2026b).



Şekil 3.5. Level-2 bulut maskeleri, Level-3 aylık ortalamalar ve bunlara ait belirsizlik haritası (CMSAF, 2026b)

CFC ürünü, Bayesian teorisine dayalı olasılıksal bir bulut maskeleye yöntemi kullanılarak piksellerin bulutlu veya açık olarak sınıflandırılmasını sağlamaktadır. Üretilen veriler, konvektif sistemlerin takibi, sis tespiti çalışmaları ve bölgesel iklim modellerinin doğrulanması süreçlerinde temel referans kaynağı olarak kullanılmaktadır. Ürünün sağladığı anlık görünüm ve aylık ortalama çıktıları arasındaki geçişler Şekil 3.5 üzerinde analiz edilebilmektedir (CMSAF, 2026c).

Veri setinin çözünürlük değerleri, Level-2 anlık verilerde alt uydu noktasında (SSP) 3×3 km² iken, Level-3 günlük ve aylık ortalamalarda $0.05^\circ \times 0.05^\circ$ enlem/boylam ızgara sistemine dönüştürülmektedir. SEVIRI sensörünün 15 dakikalık tekrarlama döngüsü, bulut özelliklerinin yüksek zamansal çözünürlükle izlenmesine olanak tanımaktadır. Şekil 3.6 'da SEVIRI'nin mekânsal kapsama alanı ve yerdeki çözünürlüğü görülmektedir.



Şekil 3.6. SEVIRI'nin mekânsal kapsama alanı ve yerdeki çözünürlüğü (CMSAF, 2026b)

CFC ürününün üretim zinciri, anlık Level-2 piksel verilerinin istatistiksel yöntemlerle Level-3 ızgaralı verilere dönüştürülmesini kapsamaktadır. Günlük ortalamaların hesaplanmasında, bir gün içindeki tüm geçerli 15 dakikalık zaman dilimleri herhangi bir ağırlıklandırma uygulanmaksızın zamansal olarak ortalanmaktadır. Aylık ortalamalar ise günlük değerlerin her gün eşit ağırlığa sahip olacak şekilde birleştirilmesiyle elde edilmektedir (CMSAF, 2026a).

Hazırlanan tüm CLAAS-3 ürünleri, dâhili sıkıştırma özelliğine sahip ve HDF5 standartlarını temel alan NetCDF-4 formatında üretilmektedir. Bu dosyalar, iklim ve tahmin (CF) üst veri konvansiyonlarına tam uyumlu bir yapıda kullanıcıya sunulmaktadır. Verilere ve ilgili teknik dokümantasyona CM SAF'ın resmi web arayüzü üzerinden erişim sağlanmaktadır (CMSAF, 2026b).

CLAAS-3 ve CFC ürünleri, tutarlı veri kaydı sayesinde iklim değişkenliğinin analizinde ve sayısal hava tahmini modellerinin iyileştirilmesinde temel referans teşkil etmektedir. Ürünün doğruluğu, yer gözlemleri ve aktif uydu sensörleri ile yapılan kapsamlı validasyon çalışmalarıyla doğrulanmıştır. Yüksek çözünürlüklü bu veriler, bulut-yüzey etkileşimlerinin ve radyasyon bütçesi üzerindeki etkilerin derinlemesine araştırılmasına imkân tanımaktadır (CMSAF, 2026c).

3.2. Metot


3.2.1. Yapay Sinir Ağları

YSA, insan beyninin biyolojik sinir ağlarının çalışma prensibini taklit eden matematiksel modellerdir. Bu sistemler, algoritmalar ile kodlanmış, önceden öğrenilmiş veya sınıflandırılmış veri setlerini kullanarak yeni bilgiler oluşturabilen ve karar verebilen yazılım uygulamaları olarak tanımlanır (Altun ve Çakar, 2020).

YSA modelleri, öğrenme kabiliyetleri ve daha önce karşılaşılmamış veriler için sonuç üretebilme yetenekleri nedeniyle büyük öneme sahiptir. Hata toleransına sahip olmaları, örüntü tanıma yapabilmeleri ve kendi kendilerine öğrenebilmeleri, karmaşık problemlerin çözümünde bu teknolojiyi ön plana çıkarmaktadır (Altun ve Çakar, 2020).

Biyolojik sinir sistemindeki nöronlar, yapay sinir ağlarında işlemci elemanları olarak karşılık bulur. Dentritler toplama fonksiyonu, sinapslar ağırlıklar, hücre gövdesi transfer fonksiyonu ve aksonlar ise yapay nöron çıkışı olarak modellenmektedir. Bilgi iletim mekanizmasında, girdiler bağlantı ağırlıklarıyla çarpılarak nöron çekirdeğine iletilir ve burada ağırlıklı toplama işlemi gerçekleştirilir (Altun ve Çakar, 2020).


YSA'nın tarihsel süreci, 1943 yılında Warren McCulloch ve Walter Pitts tarafından yayımlanan "Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap" başlıklı makale ile başlamıştır. Bu ilk model, biyolojik sinir hücrelerinin mantıksal işlemler yapabileceğini matematiksel olarak ortaya koymuştur. Şekil 3.7' de yapay sinir hücresi gösterilmiştir. (Altun ve Çakar, 2020).



Şekil 3.7. Yapay Sinir Hücresi (Altun ve Çakar, 2020)


YSA uygulamaları, altın fiyatı tahmini, veri filtreleme, sınıflandırma, veri yorumlama ve veri ilişkilendirme alanlarında etkin olarak kullanılmaktadır. Ayrıca derin öğrenme çatısı altında dil modelleme, nesne tanıma, bilgisayarlı görü ve ses işleme projelerinde temel yapı taşı oluşturmaktadır (Altun ve Çakar, 2020).

Biyolojik sinir ağı (BSA) ile YSA arasındaki temel fark, BSA'nın karmaşık kimyasal sinapslar ve devasa bir nöron bağlantı kapasitesiyle çalışmasıdır (Şekil 3.8). YSA'da ise bu biyolojik yapılar işlemci elemanları, toplama fonksiyonları ve ağırlıklar gibi matematiksel bileşenlere indirgenerek simüle edilir (Altun ve Çakar, 2020).



Şekil 3.8. Biyolojik Sinir Hücresi

Ağ mimarisi, giriş katmanı, gizli (ara) katmanlar ve çıktı katmanı olmak üzere üç ana katmandan meydana gelir (Şekil 3.9). Giriş katmanı veriyi kabul ederken, gizli katmanlar sağlanan girdilerden bilgi çıkarımı yapar ve bağlantı ağırlıklarını kullanarak bilgiyi çıktı katmanına aktarır. Aktivasyon fonksiyonları ise bu katmanlar arasında nöronların tetiklenmesini ve doğrusal olmayan özelliklerin ağı tanıtilmesini sağlar (Altun ve Çakar, 2020).



Şekil 3.9. Yapay Sinir Ağı Katmanları (Altun ve Çakar, 2020)

YSA öğrenme algoritmaları: denetimli, denetimsiz ve pekiştirmeli olmak üzere kategorize edilir. Ağırlıkların güncellenmesi ve hata değerlerinin minimize edilmesi sürecinde hatanın geriye yayılımı (backpropagation) algoritması yaygın olarak tercih edilir (Altun ve Çakar, 2020).

YSA yapısal özelliklerine göre tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli ve geri beslemeli ağlar olarak dört gruba ayrılır. İleri beslemeli ağlarda bilgi tek yönlü ilerlerken, geri beslemeli ağlarda çıktılar önceki katmanlara geri gönderilerek dinamik bir davranış oluşturulur (Altun ve Çakar, 2020).

Bir yapay nöronun işleyişi matematiksel olarak net girdinin hesaplanması ve aktivasyon fonksiyonuna tabi tutulması aşamalarından oluşmaktadır. İlk aşamada net girdi (Net), girdilerin (x_i) ağırlıklarla (w_i) çarpılıp bir eşik değeri (b) ile toplanmasıyla elde edilir:


$$\text{Net} = \sum_{i=0}^n x_i w_i + b \quad (3.1)$$

İkinci aşamada bu net değer bir aktivasyon fonksiyonuna (f) uygulanarak nöronun çıktısı (y) hesaplanmaktadır:

$$y = f(\text{Net}) \quad (3.2)$$

En yaygın olan ve çalışmamızda kullanılan ReLu aktivasyon fonksiyonudur. Şekil 3.10'da bu fonksiyonun grafiği verilmiştir. Relu aktivasyon fonksiyonunun denklemi aşağıdaki gibi ifade edilmektedir:

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (3.3)$$



Şekil 3.10. ReLu fonksiyonu ve türevi (Altun ve Çakar, 2020)

3.2.2. Karar Ağaçları ve LightGBM

Karar ağacı sınıflandırıcıları, karmaşık bir karar verme sürecinin bir dizi basit karara indirildiği hiyerarşik bir yaklaşım olarak tanımlanmaktadır. Bu modellerin en önemli özelliği, karmaşık karar süreçlerini parçalara ayırarak çözümün yorumlanmasını kolaylaştırmasıdır. Tıbbi teşhis, karakter tanıma ve radar sinyal sınıflandırması gibi pek çok alanda çözüm sunma kapasiteleri nedeniyle tercih edilmektedirler (Safavian ve Landgrebe, 1991).

Yüksek boyutlu uzaylardaki karmaşık karar bölgelerinin, yerel ve basit alt bölgelerin birleşimiyle temsil edilebilmesi karar ağaçlarının temel özelliklerinden biridir. Tek aşamalı sınıflandırıcıların aksine, her düğümde farklı öznitelik kümelerinin kullanılmasına izin verilerek işlem verimliliği artırılmaktadır. Ayrıca, gürültülü verilere karşı dayanıklılık sergilemeleri ve büyük veri setlerinde dahi yorumlanabilir sonuçlar üretmeleri modellerin öne çıkan nitelikleri arasında gösterilmektedir (Safavian ve Landgrebe, 1991).

Karar ağaçlarının temelleri, Breiman ve arkadaşları tarafından sunulan "Sınıflandırma ve Regresyon Ağaçları" (CART) çalışması ile Quinlan tarafından geliştirilen "C4.5" algoritmasına dayanmaktadır. 1990'lı yıllarda T. K. Ho tarafından rastgele öznitelik seçimiyle eğitilen karar ormanları tanıtılmış, ardından Breiman'ın "bagging" yöntemiyle bu modellerin teorik çerçevesi pekiştirilmiştir. Günümüzde ise bu yapılar, çok daha büyük ve karmaşık veri setlerini hızla işleyebilen topluluk öğrenme yöntemlerine evrilmiştir (Criminisi ve ark., 2011).

Bu modeller, tıbbi görüntü analizleri, nesne tanıma, radyolojik taramalardan otomatik teşhis ve semantik metin ayrıştırma gibi geniş bir yelpazede kullanılmaktadır. Microsoft Kinect sisteminde insan vücudu parçalarının gerçek zamanlı takibi ve 3D bilgisayarlı tomografi taramalarında organ lokalizasyonu, karar ağaçlarının endüstriyel ölçekteki en başarılı uygulama

örnekleri arasında gösterilmektedir. Modellerin paralel donanımlar üzerinde yüksek hesaplama verimliliği sunması, gerçek zamanlı uygulama alanlarındaki başarısını doğrudan desteklemektedir (Criminisi ve ark., 2011).

Karar ağacı mimarisi, düğümler ve kenarlardan oluşan, döngü içermeyen hiyerarşik bir grafik yapısı olarak kurgulanmaktadır. Yapı içerisinde hiçbir kenarın girmediği tek bir "kök düğüm" bulunur ve bu düğüm tüm sınıfları içermektedir. Her iç düğüm veriye bir test fonksiyonu uygularken, yaprak düğümler ise nihai karar veya sınıf etiketlerini barındırmaktadır (Safavian ve Landgrebe, 1991).

Modellerin eğitiminde, veriyi en uygun noktadan bölmek için genellikle 'açgözlü' (greedy) algoritmalar kullanılır. Karar ağaçları, hiyerarşik yapıları sayesinde hem sınıflandırma hem de regresyon problemlerinde uygulanabilmektedir. Süreç, her bir yaprak düğüm için en uygun tahmin değerleri belirlenene kadar özyinelemeli olarak devam eder (George, 2023).

Matematiksel bir çerçevede karar ağacı, giriş alanının k adet ayrık bölgeye $\{R_1, R_2, \dots, R_k\}$ parçalandığı ve her bölgeye bir tahmin değerinin $\{w_1, w_2, \dots, w_k\}$ eşlendiği bir modeldir. Modelin herhangi bir x girişi için ürettiği tahmin değeri şu denklemle ifade edilmektedir:

$$f(x) = \sum_{j=1}^k w_j 1[x \in R_j] \quad (3.4)$$

Burada gösterge fonksiyonu, giriş verisinin hangi bölgeye dâhil olduğunu belirleyerek ilgili ağırlık değerini sonuca yansıtmaktadır (George, 2023).

Gradyan takviyesi (Gradient Boosting), zayıf öğrencilerin sıralı bir şekilde birleştirilerek güçlü bir topluluk modeli oluşturulması sürecidir. Bu yöntemde her yeni ağaç, mevcut topluluğun tahmin hatalarını minimize etmek amacıyla kayıp fonksiyonunun gradyanını takip edecek şekilde sisteme eklenmektedir. Bu yaklaşım, modelin yanlılık (bias) miktarını azaltarak yüksek doğruluk oranlarına ulaşılmasını sağlamaktadır (George, 2023).

LightGBM, Microsoft tarafından geliştirilen ve geleneksel Gradyan Takviyeli Karar Ağacı algoritmalarının büyük veri setlerindeki verimlilik sorunlarını çözmek için tasarlanmış yüksek performanslı bir çerçevedir. Algoritma, gradyanı küçük olan verileri eleleyen "Gradyan Tabanlı Tek Taraflı Örneklem" ve seyrek öznitelikleri birleştiren "Özel Öznitelik Demetleme" tekniklerini kullanmaktadır. Bu yenilikler sayesinde LightGBM, eğitim sürecini doğruluk kaybı yaşamadan geleneksel yöntemlere kıyasla 20 kattan fazla hızlandırabilmektedir (Ke ve ark., 2017).

3.2.3. Gün Uzunluğunun Tanımlanması

Model eğitimi süreçlerinde temel girdi parametrelerinden biri olarak, çalışmada kullanılan 244 meteorolojik istasyona ait gün uzunluğu değerlerinden faydalanılmıştır. Belirli bir coğrafi

konum ve zaman dilimi için gün uzunluğu saat birimde belirlenmesinde, Eşitlik 3.5' de sunulan matematiksel bağıntı kullanılmıştır.

$$N = \frac{2}{15} \arccos(-\tan \Phi \tan \delta) \quad (3.5)$$

Burada Φ enlam açısı ve δ deklinasyon açısıdır. Deklinasyon açısı ise;

$$\delta = 23,45 * \sin(360 \frac{284+n}{365}) \quad (3.6)$$

Eşitlik 3.6 ile hesaplanır ve birimi bu eşitlikte açı cinsindendir. Güneş deklinasyon açısı, güneş ışınlarının geliş doğrultusu ile ekvator düzlemi arasında kalan açısal mesafe olarak tanımlanmaktadır. Denklemden yer alan n parametresi, Julien gün sayısıdır. n için 1 Ocak tarihi 1' i, 20 Ocak tarihi 20' yi ve yılın son günü 365 veya 366. gün sayısını temsil etmektedir.

3.2.4. Performans Hata Metrikleri

Geliştirilen tahmin modellerinden elde edilen sonuçların yer gözlem verileriyle kıyaslanması ve model performansının sayısal olarak ortaya konulması amacıyla üç temel istatistiksel indis kullanılmıştır. Modellerin açıklayıcılık gücünü ve hata miktarlarını belirlemek üzere Belirleme Katsayısı (R^2), Hata Kareler Ortalamasının Karekökü (RMSE) ve Ortalama Mutlak Hata (MAE) değerleri kullanılacaktır. Söz konusu indislerin hesaplanmasında kullanılan matematiksel eşitlikler aşağıda sunulmuştur:

$$R^2 = \frac{[\sum_{i=1}^n (E_i - \bar{E})(O_i - \bar{O})]^2}{\sum_{i=1}^n (E_i - \bar{E})^2 \sum_{i=1}^n (O_i - \bar{O})^2} \quad (3.7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (3.8)$$

$$MAE = \frac{\sum_{i=1}^n |E_i - O_i|}{n} \quad (3.9)$$

Yukarıdaki formüllerde: n toplam gözlem sayısını, E_i model tarafından tahmin edilen güneş radyasyonu değerini, O_i yer istasyonlarında piranometreler ile ölçülen gerçek güneş radyasyonu değerini, $\bar{E}$ tahmin edilen değerlerin aritmetik ortalamasını, $\bar{O}$ ise ölçülen değerlerin aritmetik ortalamasını temsil etmektedir.

4. BULGULAR VE TARTIŞMA

4.1. Yer Kayıtlarının Çalışma İçin Hazırlanması

Modelin geliştirilmesi ve performansının doğrulanması aşamalarında gereksinim duyulan yer gözlem verileri, MGM kayıtlarından temin edilmiştir. Çalışma kapsamında, 2023-2024 yıllarını kapsayan ve Türkiye genelinde 244 istasyona ait günlük toplam güneş radyasyonu ölçümleri esas alınmıştır. Veri setinin istatistiksel temsil kabiliyetini ve mekânsal kapsayıcılığını korumak amacıyla, belirtilen dönemdeki 244 istasyona ait kayıtların bütünü herhangi bir veri eksiltme yoluna gidilmeksizin model eğitim süreçlerine dâhil edilmiştir.

MGM kayıtlarından temin edilen ve çalışmada örneklem olarak seçilen 2 istasyona ait günlük toplam küresel güneş radyasyonu bilgileri ilgili çizelgelerde yer almaktadır. Bu kapsamda, 2023 yılına ait Akçakoca (17015) istasyonuna ait veriler Çizelge 4.1’te, 2024 yılına ait Adana Bölge (17351) istasyonuna ait veriler ise Çizelge 4.2’te sunulmuştur.

Çizelge 4.1. 17015 Numaralı istasyonun günlük toplam global güneş radyasyon bilgileri

Yıl: 2023 İstasyon Adı/No: AKÇAKOCA/17015												
Günlük Toplam Global Güneş Radyasyonu (kwsaat/m ²)												
Gün/Ay	1	2	3	4	5	6	7	8	9	10	11	12
1	2.5	1.2	0.9	5.1	7.5	7.2	8.4	7.4	5.9	3.1	2.3	2.0
2	2.5	1.7	0.9	2.7	7.8	8.3	8.2	7.7	4.2	1.1	1.5	2.3
3	2.6	2.1	1.4	4.8	7.5	4.6	8.0	7.6	4.8	3.6	3.1	1.6
4	2.0	1.9	2.6	2.5	5.1	3.0	7.5	7.7	4.7	5.0	2.7	0.5
5	2.2	2.1	1.4	1.3	2.1	7.9	5.8	7.6	5.7	4.8	3.1	1.6
6	1.2	0.8	3.1	4.5	1.6	8.3	6.5	7.2	5.1	4.8	1.9	0.6
7	2.2	1.9	3.4	1.4	2.0	7.6	6.5	7.5	4.9	4.8	3.2	1.2
8	2.6	2.5	2.1	6.0	2.4	4.7	1.3	4.6	2.9	4.9	2.8	0.6
9	2.7	1.3	3.5	2.9	3.2	3.9	0.9	2.0	6.1	1.4	0.8	0.4
10	2.5	1.5	3.8	0.9	4.2	8.4	7.9	4.7	6.2	3.4	3.0	1.5
11	0.7	2.0	2.1	4.3	5.4	7.8	7.9	3.8	6.3	3.2	1.8	1.8
12	1.3	3.5	1.2	1.5	1.3	2.5	7.8	4.8	6.2	4.8	1.7	1.4
13	1.2	3.9	2.1	5.4	4.3	3.4	8.0	7.2	6.2	4.7	0.8	2.3
14	0.9	3.8	4.2	6.9	6.9	7.0	7.9	5.0	6.1	3.0	3.0	2.3
15	1.6	1.2	5.5	5.3	5.3	7.6	6.3	5.9	5.9	4.3	2.8	1.4
16	2.7	2.7	1.6	2.9	7.5	8.2	7.9	3.2	5.6	1.2	1.3	0.5
17	1.9	4.4	0.7	4.5	5.9	4.7	8.0	5.7	5.8	3.7	1.8	1.2
18	1.8	3.2	1.2	1.6	3.4	6.5	8.1	6.4	5.2	1.7	1.0	2.2
19	2.8	3.7	0.7	3.3	3.0	5.6	8.0	6.8	5.3	4.4	0.9	2.2
20	3.1	0.5	2.2	3.3	6.3	4.8	8.0	6.9	6.1	4.3	1.4	2.2
21	2.9	4.2	5.4	3.5	5.1	7.4	7.7	6.3	6.4	4.1	2.5	1.5
22	2.8	4.0	1.3	7.3	4.9	8.2	8.0	6.6	6.4	4.0	2.4	1.7
23	1.2	1.8	1.1	3.4	2.4	8.3	7.2	6.5	6.2	3.6	0.9	1.8
24	0.8	3.5	5.0	7.4	4.9	7.4	7.0	5.7	5.5	3.8	1.2	1.1

25	1.5	4.0	2.8	5.5	6.6	8.3	8.1	6.6	5.1	2.9	0.8	1.9
26	3.1	3.2	2.0	4.3	7.0	7.4	7.4	6.7	4.3	1.7	0.8	2.2
27	1.2	2.4	6.1	0.9	5.2	6.8	2.5	6.5	5.0	3.2	1.8	1.0
28	1.3	1.8	1.0	5.1	4.6	8.3	7.9	5.7	2.6	3.2	2.3	2.2
29	0.8		1.8	1.8	4.6	2.0	8.1	6.4	3.6	3.1	0.5	2.3
30	1.6		2.8	6.1	3.6	8.4	7.6	6.3	4.3	2.8	0.6	2.1
31	1.4		5.4		5.6		7.7	5.6		2.4		1.4


Çizelge 4.2. 17351 Numaralı istasyonun günlük toplam global güneş radyasyon bilgileri

Yıl: 2024 İstasyon Adı/No: ADANA BÖLGE/17351												
Günlük Toplam Global Güneş Radyasyonu (kwsaat/m ²)												
Gün/Ay	1	2	3	4	5	6	7	8	9	10	11	12
1	2.2	3.5	4.7	6.2	5.9	0.8					3.5	2.9
2	1.4	3.6	4.8	6.1	5.4	3.5				0.1	3.1	2.9
3	2.5	2.9	4.5	5.7	6.1	1.9				0.6	3.1	2.8
4	1.1	3.4	4.5	6.1	5.8	1.4				0.6	3.3	0.8
5	2.3	3.1	3.6	4.5	4.1	2.1				0.6	3.7	2.5
6	2.9	3.5	2.1	6.1	7.4	2.1				0.6	3.5	2.5
7	1.7	2.5	4.1	4.5	7.8	2.7				0.5	3.5	1.5
8	0.6	1.5	4.6	4.5	7.7	7.2					3.4	1.7
9	1.2	2.5	4.2	1.7	6.3	7.4					3.2	2.4
10	1.3	3.5	5.5	3.7	6.1	2.0					2.0	2.5
11	2.3	3.7	5.5	6.5	5.6	1.3					2.9	1.7
12	2.3	2.6	5.4	6.1	3.5	0.2					3.4	2.1
13	2.5	1.7	4.3	5.3	6.2						3.2	2.6
14	3.0	0.5	4.7	5.9	6.0						2.6	2.9
15	0.7	2.4	3.1	7.1	4.1	0.2					3.0	2.3
16	1.1	2.0	5.3	6.9	6.2						3.2	0.3
17	1.1	3.6	4.8	6.7	4.4						0.4	2.7
18	1.5	3.8	2.0	6.3	4.1					0.0	2.1	2.7
19	1.3	3.7	4.7	6.1	6.8					3.1	3.0	2.5
20	1.9	3.5	4.6	3.9	6.8					4.4	2.1	2.1
21	0.5	3.9	3.4	5.9	5.5					4.4	1.9	0.6
22	2.8	4.2	3.6	6.3						4.4	0.6	1.5
23	0.7	3.9	6.1	6.3						3.8	2.5	0.4
24	3.4	4.5	6.1	6.4						4.2	0.7	0.5
25	2.9	4.6	4.4	4.9						4.2	3.2	2.3
26	0.8	3.1	4.8	4.0						4.2	3.1	0.7
27	3.5	4.2	2.2	3.9						4.1	3.1	0.9
28	3.4	4.8	5.8	4.1						4.2	3.1	2.4
29	2.7	4.8	4.5	4.2			0.2			3.1	3.0	1.2
30	0.6		6.3	3.1			0.5			3.6	3.1	2.0
31	1.4		5.8				0.0	2.8		3.4		2.8

MGM bünyesinden sağlanan bu kapsamlı veri seti, modelin eğitim ve test aşamalarında kullanılmak üzere dijital formatta tasnif edilerek ilişkisel bir veri tabanına aktarılmıştır. “tez” adlı

veri tabanına ait tablo ve görünüm yapıları Ek-1’de verilmiştir. Ön işleme sürecinde, istasyon bazlı günlük radyasyon değerleri korunarak atmosferik veri setleri ile zaman ve konum anahtarları üzerinden eşleştirilmiştir. 2023-2024 yıllarına ait 244 istasyon verisinin tamamının model eğitiminde kullanılması, modelin farklı iklim kuşakları ve topografik koşullar altında eğitilmesi sağlanmıştır.

Çalışma kapsamında kullanılan Türkiye’deki istasyonların coğrafi konumlarını gösteren harita Şekil 4.1’de yer almaktadır. Alfabetik sıraya göre düzenlenen ilk 20 istasyona ait isim, numara ve konum bilgileri Çizelge 4.3’te sunulmuştur. Çalışmada kullanılan 244 istasyona ait detaylı bilgilerin tam listesi ise Ek-2’de yer verilmiştir (Anonim 1).



Şekil 4.1. Türkiye genelindeki 244 meteorolojik istasyonun coğrafi dağılımı

Çizelge 4.3. 20 istasyona ait tanımlayıcı bilgiler ve coğrafi konumlar

İstasyon Adı	İstasyon Numarası	Enlem	Boylam
ACIPAYAM/ALCI ORMAN SAHASI	18854	37.186325305710010	29.270102186524834
ADANA BÖLGE	17351	37.004228519399860	35.344289271163790
ADIYAMAN ÜNİVERSİTESİ	18341	37.752787174499200	38.223921186516044
AFYONKARAHISAR BÖLGE	17190	38.738186372940910	30.560374000022210
AGLASUN/YUMRUTAS KÖYÜ	19158	37.599450008363780	30.682526728847005
AGRI	17099	39.730364027369350	43.055268813513980
AGRI/ÇUKURALAN KÖYÜ	19249	39.797521591206504	43.110135542350190
AKÇAKALE/KORUKLU GAP TOPRAK SU (TAGEM)	18172	36.901577749401426	38.918589542359190
AKÇAKOCA	17015	41.089681636604325	31.143006813519282
AKDENİZ ÜNİVERSİTESİ	18955	36.897788758785470	30.640600000028698
AKHISAR	17184	38.911573965829660	27.822966084685990
AKKISLA	18454	39.004635758723225	36.180577457695870
AKKUS	18131	40.803239668377250	37.014572728865250
AKSARAY	17192	38.370676642295770	33.998667813511550
AKSARAY/YESİLTEPE KÖYÜ	19197	38.433768083985260	33.881442915372170
AKSEHIR	17239	38.369219935269330	31.429581170145095
ALANYA/KESEFLİ	18837	36.400442075123750	32.177788728859820
AMASRA SAMANDIRA	17395	41.897862187376940	32.569191027576560
AMASRA	17602	41.752498072426430	32.382706000028854
AMASYA MERZIFON HAVALIMANI	17082	40.824145493334620	35.508583813513106

2023-2024 yıllarını kapsayan çalışma döneminde, 244 istasyondan elde edilen toplam 150.053 adet günlük veri kaydı tespit edilmiştir. Veri setinin mekânsal ve zamansal bütünlüğünün korunması amacıyla, herhangi bir ay veya istasyonun çalışma dışı bırakılması yoluna gidilmemiştir. Hazırlanan tüm kayıtlar, analiz süreçlerinde sistematik bir erişim sağlamak üzere ilişkisel bir veri tabanına aktarılmıştır. MGM’ den gelen veri seti Excell dosyasında olup veri tabanına aktarmak için Excell de hazırlanan arayüz ve makro Ek-3’te verilmiştir. Akçakoca istasyonuna ait 2023 yılı ocak ayına ait veriler Çizelge 4.4’ de sunulmuştur.

Kayıtlarda rastlanan veri eksiklikleri (boş günler), veri setinin genel hiyerarşisi içerisinde muhafaza edilmiştir. Bu yaklaşım ile modelin, gerçek dünya gözlem koşullarını yansıtan ham verilerle eğitilmesi ve eksik veri içeren senaryolarda dahi tahmin yeteneğinin optimize edilmesi sağlanmıştır.

Çizelge 4.4. Akçakoca/17015 istasyonuna ait 2023 yılı ocak ayına ait veriler

Satır No	Tarih	İstasyon Adı	İstasyon Numarası	Güneş Radyasyonu
1	2023-01-01	AKÇAKOCA	17015	2.50
2	2023-01-02	AKÇAKOCA	17015	2.50
3	2023-01-03	AKÇAKOCA	17015	2.60
4	2023-01-04	AKÇAKOCA	17015	2.00
5	2023-01-05	AKÇAKOCA	17015	2.20
6	2023-01-06	AKÇAKOCA	17015	1.20
7	2023-01-07	AKÇAKOCA	17015	2.20
8	2023-01-08	AKÇAKOCA	17015	2.60
9	2023-01-09	AKÇAKOCA	17015	2.70
10	2023-01-10	AKÇAKOCA	17015	2.50
11	2023-01-11	AKÇAKOCA	17015	0.70
12	2023-01-12	AKÇAKOCA	17015	1.30
13	2023-01-13	AKÇAKOCA	17015	1.20
14	2023-01-14	AKÇAKOCA	17015	0.90
15	2023-01-15	AKÇAKOCA	17015	1.60
16	2023-01-16	AKÇAKOCA	17015	2.70
17	2023-01-17	AKÇAKOCA	17015	1.90
18	2023-01-18	AKÇAKOCA	17015	1.80
19	2023-01-19	AKÇAKOCA	17015	2.80
20	2023-01-20	AKÇAKOCA	17015	3.10
21	2023-01-21	AKÇAKOCA	17015	2.90
22	2023-01-22	AKÇAKOCA	17015	2.80
23	2023-01-23	AKÇAKOCA	17015	1.20
24	2023-01-24	AKÇAKOCA	17015	0.80
25	2023-01-25	AKÇAKOCA	17015	1.50
26	2023-01-26	AKÇAKOCA	17015	3.10
27	2023-01-27	AKÇAKOCA	17015	1.20
28	2023-01-28	AKÇAKOCA	17015	1.30
29	2023-01-29	AKÇAKOCA	17015	0.80
30	2023-01-30	AKÇAKOCA	17015	1.60

4.2. Uydu Ürününün Çalışma İçin Hazırlanması

Çalışmada kullanılan uydu ürünü, İklim SAF'ına (CMSAF) ait CLAAS-3 veri setinden elde edilen CFC ürünüdür. Çalışma alanı coğrafi olarak 35° - 43° Kuzey enlemleri ile 25° - 46° Doğu boylamları arasını kapsamaktadır. Çalışma kapsamında veri setinin en güncel sürümlerinden biri olan Edition 3 (V003) kullanılacaktır. Bu veri seti, çalışmanın kapsadığı 01.01.2023 ile 31.12.2024 tarihleri arasındaki dönemi kesintisiz olarak içermektedir. Bu periyoda ait günlük ortalama veriler temini için www.cmsaf.eu web portalı üzerinden "Climate Data Records" bölümünden ilgili bağlantılar takip edilerek veri siparişi verilmiş; hazırlanan siparişler portal üzerinden indirilmiştir. Toplamda 731 adet nc uzantılı dosya elde edilmiştir.

731 adet her bir CFC dosyasında, ilgili güne ait günlük ortalama bulut kapalılık değerlerini içeren veri setleri bulunmaktadır. Verilerin istasyonların enlem ve boylam koordinat noktalarına uyması için hem Bilineer İnterpolasyon hem de En Yakın Komşu yöntemleri kullanılmıştır. İşlenen veriler, Türkiye genelindeki istasyonların enlem ve boylam bilgileriyle eşleştirilerek veri tabanına aktarılmıştır. Şekil 4.2' de 01 Ocak 2023 gününe ait CFC dosyanın bir kesiti sunulmuş olup ondalıklı değerler CFC dosyasındaki koordinatlara denk gelen Bulutluluk İndeks değerleridir. 58, 179 ve 178 değerli kırmızı noktalar istasyonlar olup bu numaralar veri tabanında istasyonların Id değerleridir.

3.0	10.0	3.0	5.0	3.0	2.0	3.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	3.0
7.0	7.0	7.0	11.0	9.0	5.0	3.0	1.0	0.0	5.0	1.0	1.0	5.0	6.0	
14.0	13.0	10.0	10.0	10.0	8.0	5.0	4.0	9.0	5.0	3.0	3.0	4.0	9.0	
20.0	10.0	12.0	14.0	17.0	8.0	6.0	10.0	4.0	3.0	3.0	3.0	3.0	4.0	
13.0	35.0	37.0	21.0	10.0	38.0	44.0	41.0	42.0	6.0	5.0	3.0	3.0	3.0	
61.0	65.0	64.0	53.0	54.0	64.0	57.0	46.0	22.0	10.0	11.0	7.0	4.0	4.0	
58.0	63.0	27.0	12.0	36.0	60.0	27.0	25.0	12.0	9.0	11.0	7.0	5.0	2.0	
52.0	18.0	13.0	9.0	15.0	14.0	12.0	9.0	8.0	9.0	11.0	8.0	4.0	15.0	

Şekil 4.2. 01 Ocak 2023 gününe ait CFC dosyasının bir kesiti

Bu çözümleme ve veritabanı entegrasyon sürecinin ardından toplam 731 adet günlük çıktı dosyası işlenmiş ve model eğitiminde kullanılacak Bulutluluk İndeksi olan 150.053 satırlık veri havuzu Bilineer İnterpolasyon ve En Yakın Komşu için ayrı ayrı oluşturulmuştur. Çizelge 4.5' te Akçakoca/17015 istasyonunun 2023 yılı ocak ayının ilk 10 gününe ait Bilineer İnterpolasyon yöntemi ile hesaplanmış bulutluluk indeks değerleri görülmektedir. Çizelge 4.6' da Akçakoca/17015 istasyonunun 2023 yılı ocak ayının ilk 10 gününe ait En Yakın Komşu yöntemi

ile hesaplanmış bulutluluk indeks deęerleri g r lmektedir. Verilerin veri tabanına kaydedilmesi i in yazılan python kaynak kodları Biliner  nterpolasyon i in Ek-4’de, En Yakın Kom u i in Ek-5’te verilmi tir.

 izelge 4.5. Ak akoca/17015 istasyonunun 2023 yılı ocak ayı ilk 10 g n ne ait Bilinear  nterpolasyon y ntemi ile hesaplanmış bulutluluk indeks deęerleri

MeteorologicalDataId	Date (Tarih)	StationNumber (�stasyon Numarası)	CloudCoverIndex (Bulutluluk �ndeksi)
1	2023-01-01	17015	1.63
2	2023-01-02	17015	0.00
3	2023-01-03	17015	0.00
4	2023-01-04	17015	50.50
5	2023-01-05	17015	38.04
6	2023-01-06	17015	93.40
7	2023-01-07	17015	65.85
8	2023-01-08	17015	8.40
9	2023-01-09	17015	0.00
10	2023-01-10	17015	56.58

 izelge 4.6. Ak akoca/17015 istasyonunun 2023 yılı ocak ayı ilk 10 g n ne ait En Yakın Kom u y ntemi ile hesaplanmış bulutluluk indeks deęerleri

MeteorologicalDataId	Date (Tarih)	StationNumber (�stasyon Numarası)	CloudCoverIndex (Bulutluluk �ndeksi)
1	2023-01-01	17015	2.00
2	2023-01-02	17015	0.00
3	2023-01-03	17015	0.00
4	2023-01-04	17015	50.00
5	2023-01-05	17015	37.00
6	2023-01-06	17015	93.00
7	2023-01-07	17015	65.00
8	2023-01-08	17015	5.00
9	2023-01-09	17015	0.00
10	2023-01-10	17015	57.00

4.3. Gün Uzunluğunun Çalışma İçin Hazırlanması

Çalışma kapsamında, 01.01.2023 ile 31.12.2024 tarihleri arasındaki her gün için istasyon bazlı maksimum gün uzunluklarının (N) hesaplanmasında python programlama dili ve bu dilin standart matematiksel işlem kütüphaneleri kullanılmıştır. Hesaplama sürecinde, her bir meteoroloji istasyonunun coğrafi enlem bilgisi ve ilgili tarihin Julien takvim yapısına göre yıl içindeki gün sırası kullanılmıştır.

Geliştirilen hesaplama algoritmasıyla öncelikle güneş dikliği (deklınasyon) belirlenmiş, ardından bu değer enlem verisiyle işlenerek gün batımı saat açısı (ws) matematiksel olarak türetilmiştir. İlgili koordinat için gün uzunluğu değerleri üretilmiştir. Hesaplanan bu değerler, analizlerde standart bir birim sağlaması amacıyla dakika birimine dönüştürülmüş ve hazırlanan "tez" isimli veri tabanındaki "daylength" tablosuna, ilgili meteorolojik verilerle eşleştirilmek üzere kaydedilmiştir. Çizelge 4.7' da Akçakoca/17015 istasyonunun 2023 yılı ocak ayının ilk 10 gününe ait hesaplanmış gün uzunluğu değerleri görülmektedir. Gün uzunluğu hesabı için yazılan python kodu Ek-6'da verilmiştir.

Çizelge 4.7. Akçakoca/17015 istasyonunun 2023 yılı ocak ayının ilk 10 gününe ait gün uzunluğu değerleri

MeteorologicalDataId	Date (Tarih)	StationNumber (İstasyon Numarası)	DayLength (Gün Uzunluğu dk.)
1	2023-01-01	17015	546.09
2	2023-01-02	17015	546.81
3	2023-01-03	17015	547.58
4	2023-01-04	17015	548.42
5	2023-01-05	17015	549.31
6	2023-01-06	17015	550.26
7	2023-01-07	17015	551.27
8	2023-01-08	17015	552.33
9	2023-01-09	17015	553.44
10	2023-01-10	17015	554.61

4.4. Yapay Sinir Ağlarının Oluşturulması ve Bulgular

Çalışma kapsamında geliştirilen YSA modelleri, Python programlama dili ve TensorFlow/Keras kütüphanesi kullanılarak ardışık bir yapıda tasarlanmıştır. Model mimarileri, girdi sayısına ve veri karmaşıklığına göre optimize edilmiş olup genellikle bir giriş katmanı, ardından gelen ve nöron sayıları 256 ile 16 arasında değişen (örneğin 128, 64, 32, 16) birden fazla gizli katman ve tek bir çıktı katmanından oluşmaktadır. Gizli katmanlarda doğrusal olmayan

ilişkileri yakalamak için ReLU, Leaky ReLU, ELU veya GELU aktivasyon fonksiyonları tercih edilmiştir. Eğitim sürecinde aşırı öğrenmeyi (overfitting) engellemek amacıyla %10 ile %20 arasında değişen oranlarda Dropout katmanları ve modelin istikrarını artırmak için BatchNormalization katmanları yapıya dâhil edilmiştir. YSA modellerinin geliştirilmesinde veri setinin %80'i eğitim ve %20'si test oranında bölünerek modeller eğitilmiştir.

Modellerin eğitiminde kullanılan girdi kombinasyonları ve bunlara atanan isimler Çizelge 4.8' de sunulmuştur.

Çizelge 4.8. Model isimleri ve girdi kombinasyonları

Model Adı	Girdi Kombinasyonu
M1	Bulutluluk İndeksi
M2	Bulutluluk İndeksi + Gün Uzunluğu
M3	Bulutluluk İndeksi + Ay
M4	Bulutluluk İndeksi + Yılın Günü
M5	Bulutluluk İndeksi + Enlem + Boylam
M6	Bulutluluk İndeksi + Gün Uzunluğu + Ay
M7	Bulutluluk İndeksi + Gün Uzunluğu + Yılın Günü
M8	Bulutluluk İndeksi + Gün Uzunluğu + Ay + Yılın Günü
M9	Bulutluluk İndeksi + Gün Uzunluğu + Enlem + Boylam
M10	Bulutluluk İndeksi + Gün Uzunluğu + Enlem + Boylam + Ay
M11	Bulutluluk İndeksi + Gün Uzunluğu + Enlem + Boylam + Yılın Günü
M12	Bulutluluk İndeksi + Enlem + Boylam + Yılın Günü
M13	Bulutluluk İndeksi + Enlem + Boylam + Ay
M14	Bulutluluk İndeksi + Gün Uzunluğu + Enlem + Boylam + Ay + Yılın Günü

Bu çalışmada güneş radyasyonu tahmin modelleri için seçilen girdi değişkenleri radyasyon miktarını fiziksel olarak belirleyen atmosferik, astronomik, coğrafi ve zamansal faktörleri temsil edecek şekilde belirlenmiştir.

Bu girdilerin kullanım gerekçeleri şunlardır:

- **Bulutluluk İndeksi:** Güneş radyasyonunun yeryüzüne ulaşmasını engelleyen en temel atmosferik faktör bulutluluktur. CLAAAS-3 veri setinden elde edilen parçalı bulut örtüsü verileri, atmosferdeki sönmelenmeyi ve radyasyon miktarındaki belirsizliği temsil etmek amacıyla temel girdi olarak seçilmiştir.
- **Gün Uzunluğu:** Belirli bir tarihte ve konumda güneşin doğuşundan batışına kadar geçen süreyi ifade eden gün uzunluğu, radyasyonun teorik olarak ulaşabileceği potansiyel üst sınırı tanımlar.

- Coğrafi Koordinatlar: Türkiye genelindeki 244 farklı istasyonun enlem ve boylam bilgileri, bölgesel iklim farklılıklarını ve güneşin geliş açısını belirleyen coğrafi konumun etkisini modele yansıtmak için kullanılmıştır.
- Zamansal Değişkenler: Dünyanın güneş etrafındaki yörüngesel hareketi nedeniyle radyasyon miktarı periyodik bir döngü izler. Ay ve Yılın Günü değişkenleri, modele mevsimsel değişimleri ve bu periyodik döngüleri tanıtmak için girdi setine dâhil edilmiştir.

Modellerin eğitiminde, kayıp fonksiyonu olarak Ortalama Kare Hata (MSE) ve optimizasyon algoritması olarak Adam kullanılmıştır. Eğitim başarısını maksimize etmek için doğrulama kaybını (val_loss) izleyen ve belirli bir süre iyileşme olmadığında eğitimi durdurarak en iyi ağırlıkları geri yükleyen EarlyStopping mekanizması ve öğrenme hızını dinamik olarak ayarlayan ReduceLROnPlateau fonksiyonu uygulanmıştır. Modellerin eğitim süreleri girdi setine bağlı olarak büyük farklılıklar göstermekte olup temel modeller (M1) yaklaşık 81-149 saniyede tamamlanırken, coğrafi ve zamansal verilerin birleştiği daha derin modellerde (M12) bu süre 1558 saniyeye kadar ulaşmaktadır. Model eğitimi için geliştirilen python kodları Ek-7’ de yer almaktadır.

Çizelge 4.9’ da YSA ve bilinear interpolasyon ile eğitilen modellerin sonuçları verilmiştir. Modellerde tek başına bulutluluk verisinin (M1) güneş radyasyonu tahminindeki başarısı 0,32 R^2 skoru ile sınırlı kalmıştır. Bu baz modelde hata metrikleri RMSE için 1,9 kWh/m² ve MAE için 1,5 kWh/m² olarak saptanmıştır. Bu sonuçlar, yerdeki radyasyon değişimlerini sadece uydu tabanlı bulutluluk indeks verisiyle açıklamanın yüksek hata payı barındırdığını göstermektedir.

Çizelge 4.9. YSA ve bilinear interpolasyon ile eğitilen modellerin sonuçları

Model Adı	R^2	RMSE	MAE	Süre
M1	0,32	1,94	1,52	81,16 sn
M2	0,61	1,46	1,91	454,30 sn
M3	0,61	1,46	0,93	249,55 sn
M4	0,62	1,45	0,91	544,84 sn
M5	0,43	1,77	1,40	870,61 sn
M6	0,62	1,45	0,90	318,26 sn
M7	0,62	1,45	0,91	470,76 sn
M8	0,62	1,45	0,91	465,38 sn
M9	0,73	1,21	0,78	697,41 sn
M10	0,75	1,70	0,75	849,12 sn
M11	0,73	1,22	0,79	376,41 sn
M12	0,76	1,15	0,75	1069,64 sn
M13	0,73	1,21	0,81	593,13 sn
M14	0,73	1,21	0,77	494,64 sn

Girdi kombinasyonları zenginleştirildikçe bilinear temelli modellerin başarısında önemli bir artış gözlemlenmiştir. Özellikle istasyon koordinatlarının ve yılın gün değerinin eklendiği M12 modelinde, R^2 değeri 0,76'e kadar yükselmiş, RMSE 1,1 kWh/m² ve MAE 0,7 kWh/m² seviyelerine düşmüştür. Bu modelin eğitim süresi ise 1069,64 saniye olarak kaydedilmiştir.

Çizelge 4.10' da en yakın komşu yöntemiyle indirgenen verilerle kurulan YSA modellerinin sonuçları verilmiştir. Başlangıç aşamasında (M1) bilinear yöntemiyle benzer şekilde 0,32 R^2 değeri üretmiştir. Modelin hata metrikleri RMSE için 1,9 kWh/m² ve MAE için 1,5 kWh/m² olarak hesaplanmıştır.


Çizelge 4.10. YSA ve en yakın komşu ile eğitilen modellerin sonuçları

Model Adı	R^2	RMSE	MAE	Süre
M1	0,32	1,94	1,51	149,39 sn
M2	0,62	1,45	0,91	254,59 sn
M3	0,61	1,46	0,93	234,51 sn
M4	0,62	1,45	0,91	300,53 sn
M5	0,42	1,79	1,41	451,75 sn
M6	0,62	1,45	0,90	228,52 sn
M7	0,62	1,45	0,90	180,47 sn
M8	0,62	1,45	0,90	491,45 sn
M9	0,75	1,17	0,75	600,70 sn
M10	0,74	1,19	0,77	603,28 sn
M11	0,75	1,17	0,76	665,71 sn
M12	0,77	1,11	0,72	1558,71 sn
M13	0,75	1,17	0,79	1168,71 sn
M14	0,73	1,21	0,78	584,72 sn


Girdi setleri artırıldığında, en yakın komşu yönteminin bilinear yöntemine göre daha iyi performans sergilediği saptanmıştır (Çizelge 4.10). M12 modelinde, çalışmadaki en yüksek YSA başarısı olan 0,77 R^2 , RMSE 1,1 kWh/m²'ye ve MAE 0,7 kWh/m² değerlerine ulaşılmıştır. En yakın komşu yöntemiyle hazırlanan verilerin aynı bilinear interpolasyon yöntemiyle elde edilen verilerde olduğu gibi, koordinat bazlı coğrafi değişkenlerle daha iyi bir uyum sergilediği ve tahmin doğruluğunu artırdığı sonucuna varılmıştır. Bu modelle üretilen sonuçlara 4 adet örnek Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6 da verilmiştir.

Girdi değişkenlerinin model başarısı üzerindeki etkisi incelendiğinde, en kritik sıçramanın astronomik ve coğrafi parametrelerin sisteme dâhil edilmesiyle yaşandığı görülmektedir. Sadece bulutluluk indeks verisi kullanılırken yaklaşık 0,32 olan R^2 değeri, matematiksel olarak hesaplanan gün uzunluğu parametresinin eklenmesiyle (M2) doğrudan 0,62 seviyesine çıkmıştır. Bu durum, güneşin doğuş ve batış saatleri arasındaki teorik sürenin radyasyon tahmini için temel bir referans oluşturduğunu kanıtlamaktadır.


Modelin mekânsal farkındalığını sağlayan enlem ve boylam bilgilerinin sisteme eklenmesi, tahmin başarısını %70 bandının üzerine taşımıştır. Özellikle coğrafi koordinatlar ile yılın gün değerinin birleştirildiği modellerde (M12) R^2 değerinin 0,77 seviyelerine kadar yükselmesi, Türkiye genelindeki 244 farklı istasyonun karakteristik radyasyon rejimlerinin model tarafından öğrenilebildiğini göstermektedir. Sonuç olarak yüksek doğrulukla bir radyasyon tahmini için uydu verilerinin mutlaka coğrafi ve zamansal yardımcı değişkenlerle desteklenmesi gerektiği, diğer benzer çalışmalarda olduğu gibi gözlenmiştir.




Şekil 4.3. 17190 Numaralı istasyonunun M12 model tahmin sonuçları



Şekil 4.4. 18455 Numaralı istasyonunun M12 model tahmin sonuçları



Şekil 4.5. 17298 Numaralı istasyonunun M12 model tahmin sonuçları



Şekil 4.6. 17059 Numaralı istasyonunun M12 model tahmin sonuçları

4.5. LightGBM Oluşturulması ve Bulgular

Çalışma kapsamında tasarlanan LightGBM modelleri, Python programlama dili ve lightgbm kütüphanesi kullanılarak yapılandırılmıştır. Model eğitiminde temel regresyon ayarları olarak; objective: 'regression', metric: 'rmse', n_estimators: 2000, learning_rate: 0.03 ve num_leaves: 31 parametreleri belirlenmiştir. Ayrıca aşırı öğrenmeyi (overfitting) engellemek amacıyla, test hatasındaki iyileşmenin durduğu noktayı saptayan 100 iterasyonluk bir erken durdurma (early stopping) mekanizması sisteme entegre edilmiştir. LightGBM modellerinin geliştirilmesinde veri seti %90 eğitim ve %10 test oranında bölünerek eğitim ve doğrulama süreçleri tamamlanmıştır. Çizelge 4.8' de kullanılan kombinasyonlar buradada kullanılarak model sonuçları değerlendirilmiştir.

LightGBM modellerinin en dikkat çekici özelliği, devasa veri setlerini saniyeler içerisinde işleyebilme kapasitesidir. Yapılan deneylerde, modellerin eğitim süreleri girdi karmaşıklığına bağlı olarak yaklaşık 0,46 saniye ile 7,38 saniye arasında değişmektedir. Özellikle çalışmanın en yüksek performanslı modeli olan M14, eğitimi yalnızca 5,51 saniye gibi çok kısa bir sürede tamamlamıştır. Modelin geliştirilmesinde kullanılan python kodu Ek-8' de yer almaktadır.

Bilinear interpolasyon yöntemiyle indirgenen bulutluluk verileri kullanılarak oluşturulan modellerde, girdi setinin zenginleşmesiyle doğru orantılı bir başarı artışı gözlemlenmiştir. Çizelge 4.11' de LightGBM ve bilinear interpolasyon yöntemiyle indirgenen verilerle kurulan modellerin sonuçları verilmiştir. Sadece uydu tabanlı bulutluluk indeks verisinin kullanıldığı M1 modelinde R^2

değeri 0,32 seviyesinde kalırken, hata metrikleri RMSE için 1,9 kWh/m² ve MAE için 1,5 kWh/m² olarak hesaplanmıştır. Bu sonuç, radyasyon tahmininde sadece bulutluluk oranı verisinin yeterli olmadığını teyit etmektedir.

Çizelge 4.11. LightGBM ve bilinear interpolasyon ile eğitilen modellerin sonuçları

Model Adı	R ²	RMSE	MAE	Süre
M1	0,32	1,95	1,52	0,76 sn
M2	0,62	1,44	0,90	0,92 sn
M3	0,62	1,46	0,92	0,46 sn
M4	0,62	1,44	0,89	0,47 sn
M5	0,52	1,63	1,33	3,34 sn
M6	0,63	1,44	0,89	1,52 sn
M7	0,63	1,43	0,88	2,30 sn
M8	0,63	1,43	0,89	1,76 sn
M9	0,84	0,94	0,64	7,38 sn
M10	0,85	0,91	0,62	5,19 sn
M11	0,85	0,90	0,62	5,48 sn
M12	0,85	0,90	0,62	5,29 sn
M13	0,83	0,95	0,68	4,81 sn
M14	0,85	0,90	0,62	4,96 sn

Girdi kombinasyonlarına coğrafi ve zamansal değişkenlerin eklenmesiyle modelin açıklayıcılık gücü zirveye ulaşmıştır. Bilinear interpolasyon verileriyle eğitilen modeller içerisinde en yüksek başarı, M14 kombinasyonu ile elde edilmiş olup; bu modelde $R^2 = 0,85$, $RMSE = 0,9$ kWh/m² ve $MAE = 0,6$ kWh/m² değerlerine ulaşılmıştır. Bilinear interpolasyon yönteminin, özellikle Türkiye genelindeki 244 istasyonun tamamını kapsayan büyük veri havuzunda oldukça iyi sonuçlar ürettiği saptanmıştır.

Çizelge 4.12’ de en yakın komşu yöntemiyle indirgenen verilerle kurulan LightGBM modellerinin sonuçları verilmiştir. En yakın komşu yöntemiyle hazırlanan veri seti, LightGBM modellerinde çok küçük iyileşme sunmuştur. Baz model olan M1 için R^2 değeri 0,32 olarak kaydedilmiştir. Çalışmada elde edilen mutlak en yüksek başarı skoru, en yakın komşu tabanlı M14 modelinde görülmüştür. Bu model, 0,85 R^2 değeri ile çalışmanın en başarılı tahmin sonucu olarak kayıtlara geçmiştir. Bu performans düzeyinde hata metrikleri $RMSE = 0,8$ kWh/m² ve $MAE = 0,6$ kWh/m² seviyelerine kadar düşmüştür. Bu bulgular, gradyan artırılmalı karar ağaçlarının, yerel komşuluk verileriyle beslendiğinde karmaşık radyasyon desenlerini iyi şekilde öğrenebildiğini kanıtlamaktadır.


Çizelge 4.12. LightGBM ve en yakın komşu ile eğitilen modellerin sonuçları

Model Adı	R ²	RMSE	MAE	Süre
M1	0,32	1,95	1,52	0,57 sn
M2	0,62	1,44	0,90	0,73 sn
M3	0,62	1,45	0,92	0,87 sn
M4	0,63	1,43	0,89	1,06 sn
M5	0,51	1,64	1,34	2,52 sn
M6	0,63	1,43	0,89	0,89 sn
M7	0,63	1,43	0,88	1,40 sn
M8	0,63	1,43	0,88	2,10 sn
M9	0,84	0,94	0,64	4,96 sn
M10	0,85	0,91	0,62	5,30 sn
M11	0,85	0,90	0,61	5,17 sn
M12	0,85	0,90	0,62	5,01 sn
M13	0,83	0,95	0,67	5,08 sn
M14	0,85	0,89	0,61	5,51 sn

Tahmin modellerinin başarısındaki asıl sıçrama, bulutluluk verisinin astronomik ve coğrafi parametrelerle desteklenmesiyle yaşanmıştır. Sadece bulutluluk indeks girdisi ile 0,32 olan R² değeri, matematiksel olarak hesaplanan gün uzunluğu verisinin eklenmesiyle (M2) doğrudan 0,62 seviyesine yükselmiştir. Koordinat (Enlem, Boylam) ve yılın günü gibi değişkenlerin de dâhil edildiği M14 senaryosunda ise bu değer 0,85 seviyesine ulaşarak %160'ın üzerinde bir iyileşme sağlamıştır.


Modelin karar verme sürecindeki hiyerarşiyi anlamak amacıyla gerçekleştirilen Değişken Önem (Feature Importance) analizi, başarıdaki bu artışın nedenlerini bilimsel olarak ortaya koymuştur. Şekil 4.7' deki değişken önem analizi grafiğine göre, model için en kritik değişkenin açık farkla gün uzunluğu olduğu, onu ise bulutluluk indeksi verisinin takip ettiği saptanmıştır. Bu durum, gün uzunluğunun radyasyon üzerindeki potansiyel üst sınırı belirlediğini, bulutluluğun ise bu potansiyel üzerindeki sönmüleyici etkiyi temsil ettiğini doğrulamaktadır.

Fiziksel olarak enlem daha belirleyici olsa da, modelimizde enlemin etkisi en baskın değişken olan 'Gün Uzunluğu' tarafından büyük oranda karşılanmıştır. Boylamın enlemden daha yüksek önem puanı alması ise, Türkiye'nin batısından doğusuna doğru değişen yükselti ve karasallık gibi radyasyonu etkileyen bölgesel faktörlerin model tarafından boylam üzerinden kodlanmasından kaynaklanmaktadır.




Şekil 4.7. M14 adlı modelin değişken önem analizi


LightGBM ve en yakın komşu ile eğitilen modellerin sonuçlarına 4 adet örnek Şekil 4.8, Şekil 4.9, Şekil 4.10 ve Şekil 4.11 de verilmiştir.




Şekil 4.8. 18911 Numaralı istasyonunun M14 model tahmin sonuçları



Şekil 4.9. 17190 Numaralı istasyonunun M14 model tahmin sonuçları



Şekil 4.10. 17749 Numaralı istasyonunun M14 model tahmin sonuçları



Şekil 4.11. 17232 Numaralı istasyonunun M14 model tahmin sonuçları

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, Türkiye genelindeki 244 meteoroloji istasyonundan alınan 2023-2024 yıllarına ait günlük toplam küresel güneş radyasyonu verileri ile EUMETSAT/CMSAF tarafından sunulan CLAAS-3 Edition 3 uydu veri seti entegre edilerek tahmin modelleri geliştirilmiştir. Çalışma kapsamında, MGM'den temin edilen ve birimi kWh/m² olan yer gözlem verileri, sistematik bir yapı oluşturmak amacıyla MySQL tabanlı "tez" isimli bir ilişkisel veritabanına aktarılmıştır. Toplamda 150.053 satırlık bir meteoroloji veri havuzu oluşturulmuştur. Bu veriler istasyon bilgileri, radyasyon ölçümleri ve astronomik gün uzunluğu gibi parametrelerle ilişkilendirilerek analizlere hazır hale getirilmiştir.

Kullanılan CLAAS-3 veri seti, MSG/SEVIRI uydusu tabanlı olup 0.05° x 0.05° (yaklaşık 5.5 km) mekânsal çözünürlükte günlük parçalı bulutluluk verileri sağlamaktadır. Bu verilerin yer istasyonu koordinatlarına indirgenmesi için geliştirilen python tabanlı algoritmalar sayesinde, uydu tabanlı bulutluluk indeksi ile yer gözlemleri arasındaki zamansal ve mekânsal korelasyon başarıyla kurulmuştur. 25-46° boylam ve 35-43° enlem aralığındaki Türkiye coğrafyası için hazırlanan bu modeller, bölgesel güneş enerjisi potansiyelinin izlenmesi adına kapsamlı bir veri tabanı sunmaktadır.

Çalışmanın genel bulguları, uydu tabanlı bulutluluk verilerinin makine öğrenmesi algoritmalarıyla işlendiğinde, yer gözlem istasyonu bulunmayan bölgeler için son derece güçlü bir alternatif olduğunu kanıtlamıştır. Özellikle yüksek maliyetli radyasyon ölçüm donanımlarının her noktaya kurulamadığı durumlarda, bu yöntem sayesinde güneş enerjisi santrali sahalarının belirlenmesi ve enerji yönetim stratejilerinin geliştirilmesi için güvenilir bir bilimsel altlık oluşturulmuştur. Elde edilen sonuçlar, yenilenebilir enerji planlamalarında uydu verilerinin operasyonel bir araç olarak kullanılabileceğini açıkça ortaya koymaktadır.

Uydu ızgara verilerinin noktasal istasyon koordinatlarına aktarılması sürecinde Bilineer İnterpolasyon ve En Yakın Komşu İnterpolasyon yöntemleri kullanılarak iki farklı veri hazırlığı yapılmıştır. Bilineer yönteminde çevredeki grid noktalarının ağırlıklı ortalaması alınırken, en yakın komşu yönteminde istasyona en yakın 2x2'lik alandaki noktaların ortalaması hesaplanarak veritabanına kaydedilmiştir. Bu iki farklı yaklaşım, modellerin mekânsal hassasiyetini doğrudan etkileyen bir faktör olarak değerlendirilmiştir.

Modellerin performans sonuçları incelendiğinde, LightGBM algoritmasında En Yakın Komşu yönteminin (M14 kombinasyonu ile R²: 0,8566), Bilineer yöntemine (M14 kombinasyonu ile R²: 0,8565) göre sınırlı da olsa daha yüksek başarı sergilediği saptanmıştır. YSA modellerinde de benzer bir eğilim görülmüştür. En yakın komşu tabanlı M12 modeli 0,77 R² değerine ulaşırken, bilinear tabanlı M12 modeli 0,76 seviyesinde kalmıştır. Bu durum, grid verilerinin istasyon noktalarına indirgenmesinde yerel komşuluk bilgisinin korunmasının tahmin doğruluğuna olumlu katkı sağladığını göstermektedir.

İnterpolasyon yöntemleri arasındaki bu küçük fark, uydu verisinin 0.05° gibi nispeten yüksek bir çözünürlükte sunulmasından ve Türkiye'nin karmaşık topoğrafyasından kaynaklanan yerel etkilerin en yakın komşu yöntemiyle bir miktar daha iyi temsil edilebilmesinden ileri gelmektedir. İstatistiksel metrikler her iki yöntemin de kabul edilebilir düzeyde olduğunu gösterse de, RMSE ve MAE değerlerindeki düşüşler dikkate alındığında, yüksek çözünürlüklü radyasyon tahminlerinde en yakın komşu yaklaşımının daha istikrarlı bir performans sergilediği sonucuna varılmıştır. Bu bulgu, gelecekteki çalışmalar için veriyi koordinatlara indirgeme aşamasında hangi yöntemin tercih edilmesi gerektiğine dair bilimsel bir referans sunmaktadır.

Tez çalışmasının en çarpıcı sonuçlarından biri, YSA mimarileri ile gradyan artırma tabanlı LightGBM algoritmaları arasındaki performans ve verimlilik farkıdır. YSA modellerinde ulaşılan en yüksek R^2 değeri $0,77$ seviyelerinde kalmış ve bu modellerin eğitim süreleri 1558 saniyeye kadar ulaşmıştır. YSA modelleri her ne kadar doğrusal olmayan ilişkileri yakalayabilse de, mevcut veri seti yapısında beklenen en yüksek doğruluğu sağlamakta yetersiz kalmıştır.

Buna karşılık, LightGBM algoritması tüm girdi kombinasyonlarında YSA modellerini belirgin şekilde geride bırakarak $0,85$ R^2 değerine ulaşmıştır. Daha da önemlisi, LightGBM modelleri eğitim sürecini yalnızca $5,51$ saniye gibi saniyeler mertebesinde tamamlayarak, YSA'ya göre yüzlerce kat daha hızlı bir hesaplama verimliliği sunmuştur. Bu durum, LightGBM'in büyük çaplı meteorolojik zaman serilerini işlemede ve mevsimsel döngüleri öğrenmede çok daha verimli bir algoritma olduğunu kanıtlamaktadır.

Toplu tahmin sonuçları analiz edildiğinde, LightGBM modelinin (M14) 89 farklı istasyonda $0,90$ 'ın üzerinde R^2 skoru ürettiği görülürken, YSA modelinde (M12) bu sayı 47 'de kalmıştır. LightGBM'in gradyan artırmalı karar ağacı yapısı, coğrafi koordinatlar ve takvimsel değişkenler arasındaki hiyerarşik ilişkileri daha iyi modelleyerek hata paylarını (RMSE ve MAE) minimize etmiştir. Sonuç olarak, operasyonel ve hızlı güneş radyasyonu tahmin sistemleri için LightGBM'in hem doğruluk hem de hız açısından güvenle kullanılabileceği sonucuna varılmıştır.

Modele dâhil edilen değişkenlerin tahmin başarısı üzerindeki etkisi incelendiğinde, girdi hiyerarşisinin önemini vurgulayan bilimsel bulgular elde edilmiştir. Sadece uydu tabanlı bulutluluk indeksinin kullanıldığı baz modellerde (M1) açıklayıcı gücün $\%32$ seviyelerinde kalması, atmosferik kapalılık bilgisinin radyasyonu tek başına açıklamakta yetersiz kaldığını göstermektedir. Ancak modele matematiksel olarak hesaplanan Gün Uzunluğu parametresinin eklenmesiyle (M2), R^2 değerinin aniden $\%62$ seviyelerine çıkması, radyasyon üzerindeki ana belirleyicinin astronomik faktörler olduğunu kanıtlamaktadır.

Model performansındaki asıl sıçrama, mekânsal farkındalık sağlayan enlem ve boylam bilgilerinin takvimsel verilerle (Yılın günü) birleştirilmesi sonucunda yaşanmış ve başarı $\%85$ seviyelerine ulaşmıştır. Koordinat bilgileri, Türkiye'nin farklı bölgelerindeki radyasyon rejimlerinin karakteristik özelliklerini modele tanıtmış, böylece aynı bulutluluk oranına sahip ancak farklı coğrafyalarda bulunan noktalar arasındaki farklar isabetli şekilde ayırt edilmiştir. Bu durum,

yüksek doğrulukla bir tahmin için uydu verilerinin coğrafi ve astronomik verilerle desteklenmesinin zorunlu olduğunu göstermektedir.

LightGBM üzerinden gerçekleştirilen değişken önem analizi, model başarısı için en kritik parametrenin açık farkla Gün Uzunluğu olduğunu, onu Bulutluluk İndeksi verisinin takip ettiğini ortaya koymuştur. Gün Uzunluğu parametresi radyasyonun potansiyel üst sınırını belirlerken, Bulutluluk İndeks verisi bu potansiyeldeki sönümlenmeyi temsil ederek tahmin sürecini tamamlamaktadır. Bu bilimsel hiyerarşi, radyasyon tahmininde fiziksel parametrelerin modele doğru bir mantıksal çerçeveye sunulmasının önemini pekiştirmektedir.

Gelecekteki çalışmalarda, CLAAS-3 Edition 3 veri setinde sunulan parçalı bulutluluk indeksinin yanı sıra, farklı spektral kanallardan elde edilen bulut tipi, bulut optik kalınlığı ve bulut su-yolu gibi fiziksel ürünlerin de modele dâhil edilmesi önerilmektedir. Bu ek parametrelerin, atmosferik geçirgenliğin fiziksel doğasını daha detaylı tanımlayarak, özellikle karmaşık bulut yapılarının olduğu günlerde tahmin hatalarını daha da minimize edebileceği öngörülmektedir. Bu sayede modellerin fiziksel temelli açıklayıcılık gücü artırılabilir.

Çalışmada kullanılan veri setinin daha uzun dönemli yer gözlemleriyle genişletilmesi, modellerin mevsimsel döngüleri ve yıllık iklimsel değişimleri daha kapsamlı bir şekilde öğrenmesine olanak tanıyacaktır. Veri hacmindeki bu zamansal artış, algoritmaların genelleme yeteneğini güçlendirerek Türkiye geneli için daha düşük hata payına sahip ve operasyonel güvenilirliği yüksek tahmin modellerinin geliştirilmesine katkı sağlayacaktır.

Çalışmada elde edilen modellerin operasyonel hale getirilmesi amacıyla, CLAAS-3 ICDR verilerinin sunduğu 10 günlük gecikme payı dikkate alınarak gerçek zamanlı (real-time) bir tahmin arayüzü geliştirilebilir. Yer gözlem istasyonu bulunmayan tarım alanları veya potansiyel güneş santrali sahaları için güncel radyasyon haritaları sunan bir web portalı veya mobil uygulama, enerji planlamacıları için değerli bir karar destek aracı olacaktır. Bu tür bir sistem, akademik bulguların doğrudan uygulama alanına aktarılmasını sağlayacaktır.

Son olarak, bu çalışmada kullanılan $0.05^\circ \times 0.05^\circ$ çözünürlüklü Level-3 ürünlerin ötesine geçilerek, SEVIRI sensörünün 3 km nadir çözünürlük sunan anlık Level-2 verileriyle daha dar alanlarda mikro-ölçekli tahmin modelleri test edilebilir. Mekânsal çözünürlüğü artırmak, özellikle dağlık bölgelerdeki gölgeleme etkilerini ve yerel bulut geçişlerini daha hassas yakalamaya olanak tanıyacaktır.



KAYNAKLAR

- Altun, M., Ve Çakar, O., 2020. Yapay Zekâ ve Makine Öğrenmesi 11-12 Ders Materyali. Millî Eğitim Bakanlığı Yayınları, Ankara, 210s.
- Anonim 1: <https://mgm.gov.tr/kurumsal/bolgeler.aspx> [Son erişim tarihi: 11.01.2026].
- Cano, D., Monget, J. M., Albuissou, M., Guillard, H., Regas, N., Wald, L., 1986. A method for the determination of the global solar radiation from meteorological satellite data. Solar Energy, Vol. 37, No. 1, pp. 31-39.
- CMSAF, 2026a, Algorithm Theoretical Baseline Document (ATBD) CLAAS-3, CMSAF web sayfası: https://www.cmsaf.eu/SharedDocs/Literatur/document/2022/saf_cm_dwd_atbd_sev_cld_3_3_final_pdf.pdf?__blob=publicationFile, [Son erişim tarihi: 10/01/2026].
- CMSAF, 2026b, Product User Manual (PUM) CLAAS-3.0, CMSAF web sayfası: https://www.cmsaf.eu/SharedDocs/Literatur/document/2022/saf_cm_knmi_pum_sev_cld_3_1_final_pdf.pdf?__blob=publicationFile, [Son erişim tarihi: 10/01/2026].
- CMSAF, 2026c, Validation Report (VAL) CLAAS-3, CMSAF web sayfası: https://www.cmsaf.eu/SharedDocs/Literatur/document/2022/saf_cm_knmi_val_sev_cld_3_1_final_pdf.pdf?__blob=publicationFile, [Son erişim tarihi: 10/01/2026]
- Criminisi, A., Shotton, J., ve Konukoglu, E., 2011. Decision Forests for Classification, Regression, Density Estimation, Manifold Learning and Semi-Supervised Learning. Microsoft Research Technical Report, TR-2011-114, Cambridge, UK, 146s.
- Dong, Z., Yang, D., Reindl, T. G., Walsh, W. M., 2014. Satellite image analysis and a hybrid ESSS ANN model to forecast solar irradiance in the tropics. Energy Conversion and Management, Vol. 79, pp. 66–73.
- ECMWF, 2026, Meteosat Second Generation, ECMWF web sayfası: https://www.ecmwf.int/sites/default/files/elibrary/2000/76318-meteosat-second-generation-msg_0.pdf, [Son erişim tarihi: 07/01/2026].
- Ener Ruşen, S., 2017. Karaman ili küresel güneş radyasyonunun Heliosat metot kullanılarak belirlenmesi. Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 6, Sayı 2, ss. 467-474.
- EUMETSAT, 2026a, EUMETSAT Uyduları, EUMETSAT web sayfası: <https://www.eumetsat.int/our-satellites#main-content>, [Son erişim tarihi: 04/01/2026].
- EUMETSAT, 2026b, Meteosat Third Generation, EUMETSAT web sayfası: <https://www-cdn.eumetsat.int/files/2022-08/Meteosat%20Third%20Generation%20-%20Weather%20and%20climate%20monitoring%20like%20never%20before.pdf>, [Son erişim tarihi: 05/01/2026].

- EUMETSAT, 2026c, Meteosat First Generation User Handbook, EUMETSAT web sayfası: https://www-cdn.eumetsat.int/files/2020-04/pdf_td06_marf.pdf, [Son erişim tarihi: 06/01/2026].
- George, S., 2023. CS229 Lecture Notes: Decision Trees. Stanford University, California, 11s.
- Kaba, K., 2012. MODİS Uydu Görüntüleri Kullanılarak Güneşlenme Süresinin Türkiye İçin Hesaplanması. Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Kandirmaz, H. M., Yeğingil İ., Peştemalcı V. ve Emrahoğlu, N., 2004. Daily Global Solar Radiation Mapping of Turkey using Meteosat Satellite Data. International Journal of Remote Sensing, Vol. 25, pp.2159-2168.
- Kandirmaz, H. M., Kaba, K., 2014. Estimation of Daily Sunshine Duration from Terra and Aqua MODIS Data. Advances in Meteorology, Vol. 2014, No. 613267.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., ve Liu, T. Y., 2017. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA.
- Küçüktopçu, E., Cemek, B., Sımsek, H., 2024. Comparative analysis of single and hybrid machine learning models for daily solar radiation. Energy Reports, Vol. 11, pp. 3256–3266.
- Mefti, A., Adane, A., Bouroubi, M. Y., 2008. Satellite approach based on cloud cover classification: Estimation of hourly global solar radiation from meteosat images. Energy Conversion and Management, Vol. 49, pp. 652–659.
- MGM, 2026, Klimatolojik Rasat El Kitabı, MGM web sayfası: <https://www.mgm.gov.tr/FILES/genel/kitaplar/KlimatolojikRasatElKitabi.pdf>, [Son erişim tarihi: 02/01/2026].
- Ordoñez Palacios, L. E., Bucheli Guerrero, V., And Ordoñez, H., 2023. Integration of satellite imagery and meteorological data to estimate solar radiation using machine learning models. Journal of Universal Computer Science, Vol. 29, No. 7, pp. 738-758.
- Safavian, S. R., ve Landgrebe, D., 1991. A Survey of Decision Tree Classifier Methodology. IEEE Transactions on Systems, Man, and Cybernetics, 21(3): 660-674. doi: 10.1109/21.97458
- Şenkal, O., Kuleli, T., 2009. Estimation of solar radiation over Turkey using artificial neural network and satellite data. Applied Energy, Vol. 86, pp. 1222–1228.
- Shamim, M. A., Remesan, R., Bray, M., Han, D., 2015. An improved technique for global solar radiation estimation using numerical weather prediction. Journal of Atmospheric and Solar-Terrestrial Physics, Vol. 129, pp. 13-22.
- Yakoubi, H., El Mghouchi, Y., Abdou, N., Hajou, A., Khellouki, A., 2021. Correlating clearness index with cloud cover and other meteorological parameters for forecasting the global solar radiation over Morocco. Optik, Vol. 242, No. 167145.
- Yang, D., Jirutitijaroen, P., Walsh, W. M., 2012. Hourly solar irradiance time series forecasting using cloud cover index. Solar Energy, Vol. 86, pp. 3531–3543.

ÖZGEÇMİŞ

Sedat YILMAZ. İlk Orta ve Lise öğrenimini Hatay’da tamamladı. Fırat Üniversitesi Elektronik/Bilgisayar Öğretimi Bilgisayar Öğretmenliği Bölümü’nde 2000 yılında Lisans eğitime başladı. 2024 yılında Çukurova Üniversitesi Fen Bilimleri Enstitüsü Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Ana Bilim Dalında Yüksek Lisans eğitime başladı. Milli Eğitim Bakanlığında öğretmen olarak çalışmaktadır.







EKLER



Ek-1: Tez adlı veri tabanının yapısı

```
CREATE DATABASE `tez` /*!40100 DEFAULT CHARACTER SET utf8mb4 COLLATE  
utf8mb4_0900_ai_ci */ /*!80016 DEFAULT ENCRYPTION='N' */;
```

```
CREATE TABLE `stations` (  
  `Id` int NOT NULL,  
  `ProvinceName` varchar(255) NOT NULL,  
  `StationName` varchar(255) NOT NULL,  
  `StationNumber` int NOT NULL,  
  `Latitude` decimal(18,15) NOT NULL,  
  `Longitude` decimal(18,15) NOT NULL  
) ENGINE=InnoDB DEFAULT CHARSET=utf8mb4 COLLATE=utf8mb4_0900_ai_ci;
```

```
CREATE TABLE `meteorologicaldata` (  
  `Id` int NOT NULL AUTO_INCREMENT,  
  `Date` date NOT NULL,  
  `StationName` varchar(255) NOT NULL,  
  `StationNumber` int NOT NULL,  
  `SolarRadiation` decimal(6,2) NOT NULL,  
  PRIMARY KEY (`Id`)  
) ENGINE=InnoDB AUTO_INCREMENT=150054 DEFAULT CHARSET=utf8mb4  
COLLATE=utf8mb4_0900_ai_ci;
```

```
CREATE TABLE `daylength` (  
  `Id` int NOT NULL AUTO_INCREMENT,  
  `MeteorologicalDataId` int NOT NULL,  
  `DayLength` decimal(20,15) NOT NULL,  
  PRIMARY KEY (`Id`)  
) ENGINE=InnoDB AUTO_INCREMENT=150054 DEFAULT CHARSET=utf8mb4  
COLLATE=utf8mb4_0900_ai_ci;
```

```
CREATE TABLE `cloudcoverindex_using_bilinear_interpolate` (  
  `Id` int NOT NULL AUTO_INCREMENT,  
  `MeteorologicalDataId` int NOT NULL,  
  `CloudCoverIndex` decimal(20,15) NOT NULL,  
  PRIMARY KEY (`Id`)
```

```
) ENGINE=InnoDB AUTO_INCREMENT=150054 DEFAULT CHARSET=utf8mb4  
COLLATE=utf8mb4_0900_ai_ci;
```

```
CREATE TABLE `cloudcoverindex_using_nearest_neighbor` (
```

```
`Id` int NOT NULL AUTO_INCREMENT,  
`MeteorologicalDataId` int NOT NULL,  
`CloudCoverIndex` decimal(20,15) NOT NULL,  
PRIMARY KEY (`Id`)
```

```
) ENGINE=InnoDB AUTO_INCREMENT=150054 DEFAULT CHARSET=utf8mb4  
COLLATE=utf8mb4_0900_ai_ci;
```

```
CREATE TABLE `model3_training8_predict_with_nearestneighbor` (
```

```
`Id` int NOT NULL AUTO_INCREMENT,  
`StationNumber` varchar(20) NOT NULL,  
`StationName` varchar(255) DEFAULT NULL,  
`Province` varchar(100) DEFAULT NULL,  
`Year` int NOT NULL,  
`Month` int NOT NULL,  
`R2` decimal(10,5) DEFAULT NULL,  
`RMSE` decimal(10,5) DEFAULT NULL,  
`MAE` decimal(10,5) DEFAULT NULL,  
`ProcessDate` timestamp NULL DEFAULT CURRENT_TIMESTAMP,  
PRIMARY KEY (`Id`)
```

```
) ENGINE=InnoDB AUTO_INCREMENT=5101 DEFAULT CHARSET=utf8mb4  
COLLATE=utf8mb4_0900_ai_ci;
```

```
CREATE TABLE `model5_training17_predict_with_nearestneighbor` (
```

```
`Id` int NOT NULL AUTO_INCREMENT,  
`StationNumber` varchar(20) NOT NULL,  
`StationName` varchar(255) DEFAULT NULL,  
`Province` varchar(100) DEFAULT NULL,  
`Year` int NOT NULL,  
`Month` int NOT NULL,  
`R2` decimal(10,5) DEFAULT NULL,  
`RMSE` decimal(10,5) DEFAULT NULL,  
`MAE` decimal(10,5) DEFAULT NULL,  
`MAPE` decimal(10,5) DEFAULT NULL,
```

```

`ProcessDate` timestamp NULL DEFAULT CURRENT_TIMESTAMP,
PRIMARY KEY (`Id`)
) ENGINE=InnoDB AUTO_INCREMENT=5101 DEFAULT CHARSET=utf8mb4
COLLATE=utf8mb4_0900_ai_ci;

```

```

CREATE ALGORITHM=UNDEFINED DEFINER=`root`@`localhost` SQL SECURITY
DEFINER VIEW `view_alldatas_with_bilinearinterpolate` AS select `m`.`Id` AS
`MeteorologicalDataId`,`m`.`Date` AS `Date`,`s`.`StationNumber` AS
`StationNumber`,`s`.`Latitude` AS `Latitude`,`s`.`Longitude` AS
`Longitude`,`cc`.`CloudCoverIndex` AS `CloudCoverIndex`,`dl`.`DayLength` AS
`DayLength`,`m`.`SolarRadiation` AS `SolarRadiation` from (((`meteorologicaldata` `m` join
`stations` `s` on((`m`.`StationNumber` = `s`.`StationNumber`))) join
`cloudcoverindex_using_bilinear_interpolate` `cc` on((`m`.`Id` = `cc`.`MeteorologicalDataId`)))
join `daylength` `dl` on((`m`.`Id` = `dl`.`MeteorologicalDataId`))) where ((`m`.`SolarRadiation` is
not null) and (`cc`.`CloudCoverIndex` is not null) and (`dl`.`DayLength` is not null));

```

```

CREATE ALGORITHM=UNDEFINED DEFINER=`root`@`localhost` SQL SECURITY
DEFINER VIEW `view_alldatas_with_nearestneighbor` AS select `m`.`Id` AS
`MeteorologicalDataId`,`m`.`Date` AS `Date`,`s`.`StationNumber` AS
`StationNumber`,`s`.`Latitude` AS `Latitude`,`s`.`Longitude` AS
`Longitude`,`cc`.`CloudCoverIndex` AS `CloudCoverIndex`,`dl`.`DayLength` AS
`DayLength`,`m`.`SolarRadiation` AS `SolarRadiation` from (((`meteorologicaldata` `m` join
`stations` `s` on((`m`.`StationNumber` = `s`.`StationNumber`))) join
`cloudcoverindex_using_nearest_neighbor` `cc` on((`m`.`Id` = `cc`.`MeteorologicalDataId`))) join
`daylength` `dl` on((`m`.`Id` = `dl`.`MeteorologicalDataId`))) where ((`m`.`SolarRadiation` is not
null) and (`cc`.`CloudCoverIndex` is not null) and (`dl`.`DayLength` is not null));

```

Ek-2: 244 İstasyona Ait Tanımlayıcı Bilgiler Ve Coğrafi Konumlar

Id	İstasyon Adı	İstasyon Numarası	Enlem	Boylam
1	ACIPAYAM/ALCI ORMAN SAHASI	18854	37.186325305710010	29.270102186524834
2	ADANA BÖLGE	17351	37.004228519399860	35.344289271163790
3	ADIYAMAN ÜNİVERSİTESİ	18341	37.752787174499200	38.223921186516044
4	AFYONKARAHISAR BÖLGE	17190	38.738186372940910	30.560374000022210
5	AGLASUN/YUMRUTAS KÖYÜ	19158	37.599450008363780	30.682526728847005
6	AGRI	17099	39.730364027369350	43.055268813513980
7	AGRI/ÇUKURALAN KÖYÜ	19249	39.797521591206504	43.110135542350190
8	AKÇAKALE/KORUKLU GAP TOPRAK SU (TAGEM)	18172	36.901577749401426	38.918589542359190
9	AKÇAKOCA	17015	41.089681636604325	31.143006813519282
10	AKDENİZ ÜNİVERSİTESİ	18955	36.897788758785470	30.640600000028698
11	AKHISAR	17184	38.911573965829660	27.822966084685990
12	AKKISLA	18454	39.004635758723225	36.180577457695870
13	AKKUS	18131	40.803239668377250	37.014572728865250
14	AKSARAY	17192	38.370676642295770	33.998667813511550
15	AKSARAY/YESİLTEPE KÖYÜ	19197	38.433768083985260	33.881442915372170
16	AKSEHIR	17239	38.369219935269330	31.429581170145095
17	ALANYA/KESEFLİ	18837	36.400442075123750	32.177788728859820
18	AMASRA SAMANDIRA	17395	41.897862187376940	32.569191027576560
19	AMASRA	17602	41.752498072426430	32.382706000028854
20	AMASYA MERZIFON HAVALIMANI	17082	40.824145493334620	35.508583813513106
21	ANADOLU ÜNİVERSİTESİ	17121	39.808469077433905	30.532049457691713
22	ANKARA BÖLGE	17130	39.972548329920850	32.863962728858910
23	ANKARA ESENBGA HAVALIMANI	17128	40.116076890930316	32.986816271191080
24	ANTALYA BÖLGE	17302	36.885099627394290	30.682911000022514
25	Ardanuç/Geçitli Köyü	19901	41.039424215716316	42.242907813513874
26	ARDESEN/YESİLTEPE	17772	41.152692410782550	41.069971000027420
27	ARTVIN	17045	41.175336587330550	41.818688457696180
28	ARTVIN/YUKARIMADEN KÖYÜ	18970	41.013326006073980	41.869450728857956
29	ASKALE	18205	39.930999541477160	40.709259813508020
30	AYANCIK/AKÖREN KÖYÜ	18546	41.832389875181020	34.771410457672030
31	AYAS	18045	40.030135657462540	32.234460271157770
32	AYDIN	17234	37.841066400235940	27.837318457667017
33	AYDINTEPE	18557	40.381451290653530	40.128756286232040
34	AYVALIK	17175	39.311571983594680	26.686412386013988
35	BAFRA ORMAN SAHASI	19036	41.555499473753315	35.769732151357870
36	BAFRA/TOPRAK SU ARS.(TAGEM)	18133	41.601842713429875	35.919040207795526
37	BALIKESİR HAVALIMANI	17150	39.608514256507874	27.921563843015920
38	BALYA/ILICA ORMAN SAHASI	18812	39.907827367304390	27.841781084655935
39	BANAZ ORMAN SAHASI	18857	38.764180856412200	29.691687445079438
40	BANDIRMA HAVALIMANI	17115	40.306758544243050	27.973798915344060
41	BARTIN	17020	41.624873478124250	32.356720813491954
42	BASISKELE/YUVACIK ORMAN	18801	40.596962822321540	29.950802286034705

	SAHASI			
43	BATMAN	17282	37.863572181766320	41.154418209493905
44	BATTALGAZI/MEYVECİLİK ARS.(TAGEM)	18187	38.453207234815630	38.356356813486790
45	BAYBURT/BALLIKAYA KÖYÜ	19235	40.372976300430530	40.392998542322154
46	BAYRAMÖREN	18251	40.929026799880134	33.242510728831505
47	BERGAMA/ÇAMKÖY	18945	39.079421137377000	27.077686543341620
48	BERGAMA/İNCECIKLER ORMAN SAHASI	18823	39.241588424143174	27.147510728832383
49	BEYPAZARI/KIRBASI	18908	40.005370798830830	31.836099271158233
50	BEYSEHIR	17242	37.677853811946484	31.746332999992667
51	BEYSEHIR/YESILDAG ORMAN SAHASI	18897	37.522769674222900	31.421200271158640
52	BEYTÜSSEBAP/KATO DAGI	19923	37.610888982198490	43.045350457666714
53	BIGA/KEMER KÖYÜ	17614	40.409155725000490	27.059982271158660
54	BILECIK SEYH EDEBALI ÜNİ.	18913	40.193910275548994	29.964700542322532
55	BILECIK	17120	40.141557034204340	29.977229271160580
56	BINGÖL	17203	38.885585729642344	40.501048542322636
57	BINGÖL/SANCAK KÖYÜ	19259	39.091746541162140	40.396857813485720
58	BODRUM	17290	37.032782294835634	27.439800999993267
59	BOGAZLIYAN	17760	39.194175503753904	35.255173355815690
60	BOLU	17070	40.733846725245094	31.601775271156290
61	BOLU/ÇELE ORMAN SAHASI	19012	40.820181503521560	31.724003999995137
62	BORNOVA ORMAN SAHASI	18442	38.503382921797680	27.270672915344058
63	BORNOVA/ZEYTİNCİLİK ARS.(TAGEM)	18031	38.451909443823446	27.197878542322435
64	BOZOVA	17944	37.365296123314420	38.513400000000004
65	BUCAK/PAMUCAK ORMAN SAHASI	18842	37.432097351016480	30.676965457672022
66	BÜNYAN	18455	38.853889970968210	35.849504728836020
67	BURDUR GÖLÜ	18995	37.711721239079860	30.223213542327976
68	BURHANIYE	17722	39.498392970930640	26.975133999999997
69	BURSA YENİSEHIR HAVALIMANI	17118	40.260705120851670	29.574946271163988
70	BURSA	17116	40.231398626253075	29.013413000000007
71	ÇAMLIYAYLA/MEYVECİLİK ARS. (TAGEM)	18060	37.174978717068974	34.604656084655936
72	ÇANAKKALE	17112	40.141608437538600	26.399605271163990
73	ÇANKIRI	17080	40.608313611673600	33.610177355819920
74	ÇEKMEKÖY/ÖMERLİ	18397	41.078510925297710	29.325556000000000
75	ÇESME	17221	38.304068481922040	26.372871271163980
76	CEYLANPINAR TIGEM	17968	36.840792192840745	40.030710542328280
77	ÇİGLİ HAVALIMANI	17218	38.502585923655870	27.013344271163984
78	CIHANBEYLİ	17191	38.650791661450090	32.921838542328274
79	ÇİNE	18023	37.594951525255920	28.044711271163983
80	ÇORUM	17084	40.546271900356880	34.936167355819920
81	DATÇA	17297	36.708019331468130	27.691699999999994
82	DELİCE / TASYAZI	19022	39.998812363543680	33.920811542328280
83	DENİZLİ ÇARDAK HAVALIMANI	17257	37.793392342435430	29.711250356125510
84	DENİZLİ	17237	37.762240044685340	29.092042813491954


85	DENİZLİ/KALE	18301	37.450670347750470	28.840389271163980
86	DERELİ/KÜMBET YAYLASI	17686	40.559338172273270	38.439711271163980
87	DEVELİ	17836	38.374584605031740	35.479695271164140
88	DEVELİ/ÖKSÜT	19912	38.314625496447846	35.506947813492424
89	DIVRIGİ	17734	39.361994753603310	38.114177728835860
90	DIYARBAKIR HAVALIMANI	17280	37.881307234760620	40.208452457672024
91	DOĞUBEYAZIT	17720	39.539279301181594	44.018157186508040
92	DURSUNBEY/YAYLA ORMAN SAHASI	18431	39.465733543179745	28.781121728836020
93	DÜZCE	17072	40.843826326417440	31.148787186508040
94	EDİRNE	17050	41.676878309338780	26.550816542327970
95	EGİRDİR/BARLA	19160	38.021549039257990	30.783351457672023
96	ELAZIG BÖLGE	17201	38.644475971952396	39.256049999999995
97	ELAZIG/HARPUT	18191	38.713675801891455	39.243478542327970
98	ELMALI ORMAN SAHASI	18305	36.583343303316010	29.988611000000002
99	ELMALI	17952	36.737441752585610	29.912067813491955
100	ERGANI	17847	38.271868998346060	39.775422084655940
101	ERZİNCAN HAVALIMANI	17092	39.708680343387710	39.540055213491954
102	ERZİNCAN	17094	39.751620463512100	39.486742271163990
103	ERZURUM BÖLGE	17095	39.906014061703760	41.254465457672026
104	ESKİŞEHİR HAVALIMANI	17124	39.781574880185440	30.597809813491960
105	EZİNE/ÇAMLIÇA KÖYÜ ORMAN SAHASI	18819	39.895694320302550	26.421489542327970
106	FEKE/MANSURLU ORMAN SAHASI	18863	37.839613458094690	35.775000000000000
107	FETHİYE	17296	36.626796121764980	29.123803999999996
108	FINİKE	17375	36.302633452617600	30.145767813491950
109	GEMEREK	17162	39.185220374374630	36.080500000000000
110	GÖKSUN	17866	38.024156355736466	36.482343728836210
111	GÖLBASI ORMAN SAHASI	19080	37.580204062841524	37.481367542327970
112	GÖLBASI/YAGLIPINAR KÖYÜ	18979	39.662889961828560	32.826889271163985
113	GÜMÜŞHANE	17088	40.460400261890720	39.465389813491946
114	GÜNGÖREN/DAVUTPASA MARMARA	17814	41.026753783664610	28.885278542327970
115	HAKKARI	17285	37.574687071443440	43.738843728836010
116	HOPA SAMANDIRA	17398	41.411192882394260	41.328680728836005
117	Iğdir Üniversitesi	19903	39.801178338463660	44.071812457672024
118	IGDIR	17100	39.926093008627355	44.053720000000000
119	İKİZDERE/CİMİL	18569	40.730906928034436	40.794725728835864
120	ILGAZ DAGI	19991	41.059646245893760	33.722788728836010
121	ILGAZ TOPRAK	18904	41.067976175866170	33.726068084656570
122	İlkadım	19339	41.270272501042250	36.301569084656556
123	İNCİRLİOVA/İNCİR ARS.(TAGEM)	18026	37.863527813642900	27.664722000000000
124	İNEBOLU KAR	18911	41.874823780698190	33.718928728835856
125	İNÖNÜ/THK TESİSLERİ	19143	39.818589533122605	30.124237084655940
126	İSPARTA SÜLEYMAN DEMİREL HAVALIMANI	17241	37.849277379500606	30.360958813491960
127	İSPARTA	17240	37.785296020263560	30.566669355819922
128	İSTANBUL HAVALIMANI	17058	41.264899484362510	28.728835999999998

129	ISTANBUL SABİHA GÖKÇEN HAVALIMANI	17063	40.892967316308430	29.297225271163980
130	IVRINDI	18432	39.591985837323530	27.493803170534235
131	İZMİR BÖLGE	17220	38.394693401178536	27.082110728836014
132	İZMIT ORMAN SAHASI	18800	40.834937111434210	29.914124084656557
133	KADIKÖY/GÖZTEPE MARMARA	17813	40.979604893723610	29.057125542327974
134	KAGIZMAN	18198	40.153484705008090	43.126100271164134
135	KAPADOKYA HAVALIMANI	17194	38.778971731501280	34.523863813492426
136	KARABÜK KAPULLU	17077	41.232889267015150	32.629419271164140
137	KARABÜK/KARATEPE	18261	41.034879811129560	32.723910457671714
138	KARAMAN	17246	37.193350751940116	33.220134813492420
139	KARATAY/BAHRI DAGDAS ARS. (TAGEM)	18213	37.860721174325780	32.583846084629660
140	KARS	17097	40.606250415658370	43.111824355820694
141	KASTAMONU	17074	41.371147156537340	33.775577813492420
142	KASTAMONU/MESCİT KÖYÜ	18997	41.250034294241470	33.898872542328284
143	KAYSERİ ERKİLET HAVALIMANI	17195	38.771372477520224	35.507858000000006
144	KAYSERİ/PINARBASI	17802	38.725327958312860	36.390290626984830
145	KAZAN/SARAYKÖY TOPRAK	18903	40.088381411385650	32.605123542327980
146	KEÇİÖREN/9. (ANKARA) BÖLGE	18250	39.972672663339170	32.863856813491960
147	KEMALPASA	17749	38.464059612760290	27.370478542327970
148	KEMALPASA/OVACIK KÖYÜ	18439	38.347963111921860	27.683632457672030
149	KESTEL	18384	40.186376318588830	29.210536271163980
150	KILIS	17262	36.708569318098900	37.112032728835860
151	KIRIKKALE	17135	39.843497583207730	33.518048542328290
152	KIRKGAÇ	19137	39.108377639770390	27.692647915343443
153	KIRKLARELİ	17052	41.738359147674420	27.217845000000000
154	KİRSEHİR	17160	39.165183045328160	34.155918271386014
155	KIZILCAHAMAM/YILDIRIM ORMAN SAHASI	19006	40.494463484494570	32.737092952505620
156	KOCAELİ	17066	40.766502894118620	29.917309138528736
157	KOCASINAN/HİMMETDEDE KÖYÜ	18923	38.941234758070976	35.058227271164135
158	KOCATEPE ÜNİVERSİTESİ	17839	38.835103860148020	30.531941457672026
159	KORKUTELİ/BÜK ORMAN SAHASI	18015	36.970443007151600	30.433866271163986
160	KOZAN/ACARYAYLA ORMAN SAHASI	18861	37.530670165401425	35.896978542327965
161	KULU	17754	39.079028721180634	33.065677728811146
162	KURUNLU/DUMANLI KÖYÜ	19211	40.695308958616240	33.251407813491950
163	KUSADASI	17232	37.859945293694550	27.265205271163985
164	KÜTAHYA	17155	39.417313913882140	29.989033813472094
165	LÜLEBURGAZ/CELALİYE KÖYÜ	19113	41.528344813902706	27.369310728835860
166	Maçka /Hamsiköy	19902	40.662511423460170	39.415322457671714
167	MALATYA	17199	38.336847932566734	38.217365186489445
168	MALATYA/KAYISI ARS. ENS.	18353	38.322963218536950	38.285390626984840
169	MALAZGİRT	17780	39.143791615908600	42.530771728835860
170	MANAVGAT ORMAN SAHASI	18839	36.861586432309600	31.675545271163983

171	MANISA	17186	38.615500851576500	27.404940999999997
172	MARDIN	17275	37.310619932836560	40.727993271164130
173	MARMARIS	17298	36.839487542167430	28.244995000000003
174	MENEMEN	17789	38.623906404485680	27.043269728836020
175	MERKEZEFENDI	19359	37.776322004308994	29.016048542327972
176	MIHALIÇCIK/ÇATACIK	18089	39.968530341524854	31.131656271163994
177	MIHALIÇCIK/KIZILTEPE ORMAN SAHASI	18833	40.021030189882914	31.181965457672020
178	MILAS ORMAN SAHASI	18849	37.305616012254690	27.908946813492420
179	MILAS/DENİZCIK ORMAN DEPOSU	18020	37.254376222420670	27.796378271164140
180	MUGLA DALAMAN HAVALIMANI	17295	36.702711133758340	28.790642457671716
181	MUGLA	17292	37.209686801702860	28.366855457671720
182	MUS/BERCE ALPARSLAN TARIM ISLETMESI	18916	38.796221141478860	41.509476186507580
183	MUSTAFAKEMALPASA/GÜRGE NDAG ORMAN SAHASI	18831	39.843487939630140	28.572644542327968
184	NEVSEHIR	17193	38.616487466314880	34.702493728835860
185	NIGDE	17250	37.958690332206180	34.679467813492420
186	ODUNPAZARI/KIREÇKÖYÜ	18946	39.772161907250670	30.781837542327974
187	PALANDÖKEN KAYAK MERKEZI	17777	39.844600511526490	41.290256542327974
188	PALU	17806	38.696325591677250	39.932583813491950
189	PAMUKOVA	19118	40.488193593645240	30.175567084656556
190	PASINLER/TOprak su ARS. (TAGEM)	18201	39.990221938791690	41.574134813491950
191	PAZARCIK/ÇINARLI	18988	37.462083095904340	37.079721457672430
192	PINARBASI KAR	18519	41.556847752035450	33.078843542328280
193	PINARBASI/PAZARSU KÖYÜ	19187	39.104429999580695	36.649487728835850
194	PÜTÜRGE ORMAN SAHASI	19088	38.332975774118150	38.886645542328274
195	REFAHIYE/YURTBASI KÖYÜ	19252	39.882833122952250	39.032329457672034
196	RIZE	17040	41.040182075131390	40.501343728835856
197	SAFRANBOLU ORMAN SAHASI	19010	41.359609082983750	32.698045271164140
198	SAKARYA	17069	40.767397576309640	30.393820271164140
199	SAMANDIRA HAVALIMANI	17065	40.986862271948930	29.214898271163980
200	SARIKAMIS KAYAK MERKEZI	18196	40.296724567518496	42.582240999999996
201	SARIYER/ITÜ MASLAK YERLESKESİ	18980	41.100094951726994	29.025127000000005
202	SARIYER/KUMKÖY-KILYOS	17059	41.250773907686800	29.033290341086396
203	Sarkikaraağaç/Kizildag Milli Parki	19905	38.042016891256516	31.368110999999992
204	SEYITGAZI/YENIKENT KÖYÜ	19146	39.569982946658320	30.742868813491956
205	SIIRT	17210	37.932101863372100	41.935378271164150
206	SILIFKE/AKDERE ORMAN SAHASI	18870	36.225358426459260	33.722423000000006
207	SILIFKE/TASUCU AÇIKLARI SAMANDIRA	17394	36.130876338118580	33.866961214454754
208	SILIVRI ORMAN SAHASI	18793	41.306574365934640	28.186986915344060
209	SIMAV/SÖĞÜT ORMAN SAHASI	18836	39.165986888248020	29.082200542314332

210	SINANPASA/TAZLAR KÖYÜ	19166	38.763874044014430	30.082789999999992
211	SINANPASA/TINAZTEPE BELDESİ	18912	38.723342518910160	30.377148542327970
212	SINOP	17026	42.030079371042200	35.154469999999990
213	SIRNAK	17287	37.520518424403946	42.445088271164140
214	SIVAS	17090	39.743827865765340	37.001999999999995
215	SOLHAN	17776	38.966580887345856	41.050337000000006
216	SULTANDAGI	18006	38.530953250382240	31.219707000000007
217	SUMBAS	19184	37.465916180509700	36.023794271164140
218	SUSEHRI	17684	40.162509282421420	38.075145542328286
219	TALAS/ERCIYES ÜNİVERSİTESİ	19188	38.709867881322130	35.546500457671720
220	TARSUS	17978	36.894368637751810	34.959711271164140
221	TARSUS/ARDIÇLI	18206	37.231566574325920	34.736621457671724
222	TASOVA/BORABOY ORMAN SAHASI	19025	40.859630630891840	36.103056000000000
223	TATVAN/NEMRUT KAYAK MERKEZİ	18584	38.576148302455950	42.277232813491956
224	TEKIRDAG ÇORLU HAVALIMANI	17051	41.131068985589806	27.909683084656557
225	TEKIRDAG	17056	40.958116995006660	27.496116626984840
226	TEKKEKÖY/KARADENİZ ARS. (TAGEM)	18132	41.230459547756410	36.498621728835860
227	TERCAN	17718	39.777050402074025	40.390547271163980
228	TOKAT	17086	40.331367379502815	36.557666999999995
229	TOKAT/TOprak ve su ARS. (TAGEM)	18147	40.326295035800700	36.449967813492420
230	TOROSLAR/ARSLANKÖY	18287	37.058257203970790	34.362778000000000
231	TORTUM	17688	40.301521194520910	41.540855999999990
232	TUNCELI	17165	39.109873310687670	39.545696728835864
233	TUNCELI/OVACIK	18179	39.368234327804920	39.241976186507580
234	ULUKISLA	17906	37.548191391124570	34.486688457671720
235	ÜNYE	17624	41.143402789292640	37.292788813492420
236	VAN BÖLGE	17172	38.469361201459380	43.345994271164145
237	VEZİRKÖPRÜ/GÖLKÖY ORMAN SAHASI	19038	41.179520313729350	35.156129542328290
238	VİZE/YUMURTATEPE	18408	41.708586242290060	27.865542728835848
239	YAKAKENT	19226	41.629210533063010	35.556599999999990
240	YALIHÜYÜK	18500	37.291623118903640	32.111877999974894
241	YALOVA	17119	40.660527121380670	29.286619271164135
242	YOZGAT/ESENLİ KÖYÜ	19907	39.608156713561430	35.075545000000000
243	YÜREGİR/ÇUKUROVA TARIM ARS. (TAGEM)	18054	36.854281111809380	35.346678813491955
244	ZONGULDAK	17022	41.449514938141200	31.778302813492420

Ek-3: Yer Ölçüm Güneş Radyasyonlarının Veri Tabanına Aktarılması İçin Arayüz Ve Makro



Düğmenin Click Yordamı:

```
Private Sub CommandButton1_Click()
```

```
    Dim conn As ADODB.Connection
```

```
    Dim cmd As ADODB.Command
```

```
    Dim connStr As String
```

```
    Set conn = New ADODB.Connection
```

```
    connStr = "Driver={MySQL ODBC 9.2 Unicode Driver};" & _
```

```
        "Server=localhost;" & _
```

```
        "Port=3306;" & _
```

```
        "Database=tez;" & _
```

```
        "User=root;" & _
```

```
        "Password=1234;" & _
```

```
        "Option=3;"
```

```
    On Error GoTo HataMesaji
```

```
    conn.Open connStr
```

```
    Set cmd = New ADODB.Command
```

```
    Set cmd.ActiveConnection = conn
```

```
    cmd.CommandType = adCmdText
```

```
    Dim stationText, column, row, yearValue, srValue, stationName, stationNumber, sql
```

```
    Dim ws As Worksheet
```

```
    Set ws = ThisWorkbook.Sheets("Report")
```

```

column = 2
row = 3
Dim dolu As Long: dolu = 0
Dim boş As Long: boş = 0

Dim z As Integer
For z = 1 To 470
    Label1.Caption = "İstasyon No:" & z
    DoEvents

    stationText = ws.Cells(row, column).Value
    If stationText = "" Then Exit For ' Boş satıra gelirse dur

    ' Veri ayrıştırma (Örn: "Yıl: 2023 İstasyon Adı/No: ANKARA/17060")
    yearValue = Mid(stationText, 6, 4)

    Dim fullStationInfo As String
    fullStationInfo = Mid(stationText, 29, Len(stationText))

    If InStr(fullStationInfo, "/") > 0 Then
        Dim parts As Variant
        parts = Split(fullStationInfo, "/")
        stationNumber = parts(UBound(parts))

        Dim namePart As String
        namePart = ""

        Dim k As Integer
        For k = 0 To UBound(parts) - 1
            namePart = namePart & parts(k) & IIf(k < UBound(parts) - 1, "/", "")
        Next k
        stationName = namePart
    Else
        stationName = fullStationInfo
        stationNumber = 0
    End If

    Dim i As Integer, j As Integer

```

```

For i = 1 To 12 ' Aylar
    For j = 1 To 31 ' Günler
        srValue = ws.Cells(row + 3 + j, column + i).Value

        If srValue = "" Or Not IsNumeric(srValue) Then
            boş = boş + 1
            Label3.Caption = "Boş hücre: " & boş
            GoTo NextDay
        End If

        Dim formattedSR As String
        formattedSR = Replace(CStr(srValue), ",", ".")

        dolu = dolu + 1
        Label2.Caption = "Dolu hücre: " & dolu

        sql = "INSERT INTO meteorologicaldata (Date, StationName, StationNumber, SRValue)
VALUES " & _
        "(" & yearValue & "-" & Format(i, "00") & "-" & Format(j, "00") & ", " & _
        "'" & stationName & "'", " & _
        "'" & stationNumber & "'", " & _
        "'" & formattedSR & "');"

        cmd.CommandText = sql
        cmd.Execute

        DoEvents
    NextDay:
        Next j
    Next i

    row = row + 39
    Label4.Caption = "Toplam:" & (dolu + boş)
Next z

```

MsgBox "Veriler başarıyla MySQL'e aktarıldı!", vbInformation

Temizlik:

If conn.State = adStateOpen Then conn.Close

Set conn = Nothing

Exit Sub

HataMesaji:

MsgBox "Hata oluştu: " & Err.Description, vbCritical

Resume Temizlik

End Sub



Ek-4: Bilinear İnterpolasyon İle Bulutluluk İndeks Hesabı İçin Python Kodu

```
import mysql.connector
import numpy as np
from netCDF4 import Dataset
import os
from datetime import datetime

# 1. Ayarlar
BASE_DIR = r"" # .nc dosyalarının olduğu klasör yolu
DB_CONFIG = {
    'host': 'localhost',
    'user': 'root',
    'password': '1234',
    'database': 'tez'
}

def get_db_connection():
    return mysql.connector.connect(**DB_CONFIG)

def bilinear_interpolate(lat_target, lon_target, lat_grid, lon_grid, data_grid):
    # En yakın indeksleri bul
    i = np.searchsorted(lat_grid, lat_target) - 1
    j = np.searchsorted(lon_grid, lon_target) - 1

    # Grid sınır kontrolü
    if i < 0 or i >= len(lat_grid)-1 or j < 0 or j >= len(lon_grid)-1:
        return None

    # Köşe noktalarının koordinatları
    lat1, lat2 = lat_grid[i], lat_grid[i+1]
    lon1, lon2 = lon_grid[j], lon_grid[j+1]

    # Köşe noktalarının değerleri
    q11 = data_grid[i, j]
    q12 = data_grid[i, j+1]
    q21 = data_grid[i+1, j]
```

```

q22 = data_grid[i+1, j+1]

# Bilinear Interpolation Formülü

denom = (lon2 - lon1) * (lat2 - lat1)
val = (q11 * (lon2 - lon_target) * (lat2 - lat_target) +
      q21 * (lon_target - lon1) * (lat2 - lat_target) +
      q12 * (lon2 - lon_target) * (lat_target - lat1) +
      q22 * (lon_target - lon1) * (lat_target - lat1)) / denom
return float(val)

def process_cloud_index():
    conn = get_db_connection()
    cursor = conn.cursor(dictionary=True)

    # İstasyonları ve tarihlerini çek
    cursor.execute("SELECT m.Id as MetId, m.Date, s.Latitude, s.Longitude "
                  "FROM meteorologicaldata m JOIN stations s ON m.StationNumber = "
                  "s.StationNumber")
    all_tasks = cursor.fetchall()

    # Tarihe göre gruplandır
    tasks_by_date = {}
    for task in all_tasks:
        d_str = task['Date'].strftime("%Y%m%d")
        if d_str not in tasks_by_date:
            tasks_by_date[d_str] = []
        tasks_by_date[d_str].append(task)

    insert_query = "INSERT INTO cloudcoverindex_using_bilinear_interpolate "
    (MeteorologicalDataId, CloudCoverIndex) VALUES (%s, %s)"

    for date_str, stations in tasks_by_date.items():
        filename = f"CFCdm{date_str}0000004UDSVMSGI1UD.nc"
        filepath = os.path.join(BASE_DIR, filename)

        if not os.path.exists(filepath):

```

```

print(f'Dosya bulunamadı: {filename}')
continue

try:
    # NetCDF dosyasını aç
    nc = Dataset(filepath, 'r')
    lats = nc.variables['lat'][:]
    lons = nc.variables['lon'][:]
    cfc_data = nc.variables['cfc'][0, :, :]

    batch_insert = []
    for s in stations:
        val = bilinear_interpolate(float(s['Latitude']), float(s['Longitude']), lats, lons, cfc_data)
        if val is not None:
            batch_insert.append((s['MetId'], val))

    if batch_insert:
        cursor.executemany(insert_query, batch_insert)
        conn.commit()
        print(f'{date_str} tarihi için {len(batch_insert)} kayıt eklendi.')

    nc.close()
except Exception as e:
    print(f'{filename} işlenirken hata: {e}')

cursor.close()
conn.close()

if __name__ == "__main__":
    process_cloud_index()

```

Ek-5: En Yakın Komşu İle Bulutluluk İndeks Hesabı İçin Python Kodu

```
import mysql.connector
import numpy as np
from netCDF4 import Dataset
import os

# 1. Ayarlar
BASE_DIR = r""
DB_CONFIG = {
    'host': 'localhost',
    'user': 'root',
    'password': '1234',
    'database': 'tez'
}

def get_db_connection():
    return mysql.connector.connect(**DB_CONFIG)

def get_average_of_nearest(lat_target, lon_target, lat_grid, lon_grid, data_grid, tolerance=0.0001):
    lat_idx = (np.abs(lat_grid - lat_target)).argmin()
    lon_idx = (np.abs(lon_grid - lon_target)).argmin()

    distances = []
    values = []

    # En yakın noktanın etrafındaki 4 komşuyu kontrol et
    for i in range(max(0, lat_idx-1), min(len(lat_grid), lat_idx+2)):
        for j in range(max(0, lon_idx-1), min(len(lon_grid), lon_idx+2)):
            dist = np.sqrt((lat_grid[i] - lat_target)**2 + (lon_grid[j] - lon_target)**2)
            val = data_grid[i, j]
            if not np.ma.is_masked(val):
                distances.append(dist)
                values.append(float(val))

    if not distances:
        return None
```

```

# En kısa mesafeyi bul
min_dist = min(distances)

nearest_values = [values[k] for k in range(len(distances)) if distances[k] <= min_dist +
tolerance]

# Seçilen en yakınların ortalamasını al
return sum(nearest_values) / len(nearest_values)

def process_hybrid_neighbor():
    conn = get_db_connection()
    cursor = conn.cursor(dictionary=True)

    # Verileri çek
    cursor.execute("SELECT m.Id as MetId, m.Date, s.Latitude, s.Longitude "
        "FROM meteorologicaldata m JOIN stations s ON m.StationNumber =
s.StationNumber")
    all_tasks = cursor.fetchall()

    # Tarihe göre grupta
    tasks_by_date = {}
    for task in all_tasks:
        d_str = task['Date'].strftime("%Y%m%d")
        if d_str not in tasks_by_date: tasks_by_date[d_str] = []
        tasks_by_date[d_str].append(task)

    # tabloya kayıt
    insert_query = "INSERT INTO cloudcoverindex_using_nearest_neighbor
(MeteorologicalDataId, CloudCoverIndex) VALUES (%s, %s)"

    for date_str, stations in tasks_by_date.items():
        filename = f"CFCdm{date_str}0000004UDSVMSGI1UD.nc"
        filepath = os.path.join(BASE_DIR, filename)

        if not os.path.exists(filepath): continue

```

```

try:
    nc = Dataset(filepath, 'r')
    lats = nc.variables['lat'][:]
    lons = nc.variables['lon'][:]
    cfc_data = nc.variables['cfc'][0, :, :]

    batch_insert = []
    for s in stations:
        val = get_average_of_nearest(float(s['Latitude']), float(s['Longitude']), lats, lons,
cfc_data)
        if val is not None:
            batch_insert.append((s['MetId'], val))

    if batch_insert:
        cursor.executemany(insert_query, batch_insert)
        conn.commit()
        print(f"{date_str}: {len(batch_insert)} kayıt ortalama yöntemiyle eklendi.")

    nc.close()
except Exception as e:
    print(f"Hata: {e}")

cursor.close()
conn.close()

if __name__ == "__main__":
    process_hybrid_neighbor()

```

Ek-6: İstasyonların Gün Uzunluğu Hesabı İçin Python Kodu

```
import mysql.connector
import math
from datetime import datetime

# 1. MySQL Bağlantı Yapılandırması
def get_db_connection():
    return mysql.connector.connect(
        host="localhost",
        port="3306",
        user="root",
        password="1234",
        database="tez"
    )

# 2. Gün Uzunluğu Hesaplama Fonksiyonu
def calculate_day_length_minutes(latitude, date_obj):
    # Yılın günü (1-365)
    day_of_year = date_obj.timetuple().tm_yday

    # Enlemi radyana çevir
    lat_rad = math.radians(float(latitude))

    # Güneş Deklinasyonu ( $\delta$ )
    # Formül:  $23.45 * \sin(360/365 * (284 + n))$ 
    declination = math.radians(23.45 * math.sin(math.radians(360 / 365 * (284 + day_of_year))))

    # Gün Batımı Saat Açısı (ws)
    cos_ws = -math.tan(lat_rad) * math.tan(declination)

    if cos_ws > 1:
        return 0.0
    elif cos_ws < -1:
        return 1440.0

    ws = math.acos(cos_ws)
```

```

# Gün Uzunluğu (Saat)
day_length_hours = (24 / math.pi) * ws

# Dakikaya çevir
return day_length_hours * 60

def main():
    try:
        conn = get_db_connection()
        cursor = conn.cursor(dictionary=True)

        # 3. Verileri Çekme
        query = """
        SELECT m.Id AS MeteorologicalDataId, m.Date, s.Latitude
        FROM meteorologicaldata m
        JOIN stations s ON m.StationNumber = s.StationNumber
        """

        cursor.execute(query)
        records = cursor.fetchall()

        print(f'{len(records)} adet kayıt işleniyor...")

        insert_query = "INSERT INTO daylength (MeteorologicalDataId, DayLength) VALUES (%s,
%s)"

        batch_data = []
        counter = 0

        for row in records:
            m_id = row['MeteorologicalDataId']
            m_date = row['Date']
            lat = row['Latitude']

```

```

# Dakika cinsinden hesapla
duration_min = calculate_day_length_minutes(lat, m_date)

batch_data.append((m_id, duration_min))
counter += 1

if len(batch_data) >= 1000:
    cursor.executemany(insert_query, batch_data)
    conn.commit()
    batch_data = []
    print(f'{counter} kayıt tamamlandı...')

# Kalan verileri yaz
if batch_data:
    cursor.executemany(insert_query, batch_data)
    conn.commit()

print("\nİşlem başarıyla tamamlandı. Tüm veriler 'daylength' tablosuna dakika olarak kaydedildi.")

except mysql.connector.Error as err:
    print(f'Veritabanı hatası: {err}')
finally:
    if 'conn' in locals() and conn.is_connected():
        cursor.close()
        conn.close()

if __name__ == "__main__":
    main()

```

Ek-7: Python Yapay Sinir Ağları Model Kodu

```
import pandas as pd
import numpy as np
import mysql.connector
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Input, BatchNormalization
import joblib
import matplotlib.pyplot as plt
from tensorflow.keras.callbacks import EarlyStopping
from scipy.stats import pearsonr
import time

# 1. Veri Çekme (MySQL)
def get_data():
    db_config = {
        'host': 'localhost',
        'user': 'root',
        'password': '1234',
        'database': 'tez'
    }

    query = """
    SELECT Date, Longitude, Latitude, CloudCoverIndex, DayLength, MONTH(Date) as Month,
    SolarRadiation
    FROM View_AllDatas_With_NearestNeighbor
    """

    conn = mysql.connector.connect(**db_config)
    df = pd.read_sql(query, conn)
    conn.close()
```

```

    return df

print("Veritabanından veriler okunuyor...")
df = get_data()

# 2. Veri Hazırlığı
df['DayOfYear'] = pd.to_datetime(df['Date']).dt.dayofyear

X = df[['Longitude', 'Latitude', 'CloudCoverIndex', 'DayOfYear']].values
y = df['SolarRadiation'].values

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Ölçeklendirme
scaler_X = StandardScaler()
scaler_y = StandardScaler()

X_train_scaled = scaler_X.fit_transform(X_train)
X_test_scaled = scaler_X.transform(X_test)
y_train_scaled = scaler_y.fit_transform(y_train.reshape(-1, 1))

# 3. Model Yapısı (Girdi sayısı 4)
"""
model = Sequential([
    Input(shape=(4,)),
    Dense(128, activation='relu'),
    Dropout(0.1),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(1)
])

model.compile(optimizer='adam', loss='mse', metrics=['mae'])
"""

model = Sequential([

```

```

Input(shape=(4,)),
Dense(256, activation='relu'),
Dropout(0.1),
Dense(128, activation='relu'),
Dense(64, activation='relu'),
Dense(32, activation='relu'),
Dense(16, activation='relu'),
Dense(1)
])
"""

--- MODEL PERFORMANS SONUÇLARI ---
R-Kare (R2) Skoru: 0.7787
RMSE (Kök Ortalama Kare Hatası): 1.1142
MAE (Ortalama Mutlak Hata): 0.7255
Model eğitimi tamamlandı. Süre: 1558.71 saniye.
"""

```

```

model = Sequential([
    Input(shape=(4,)),
    Dense(256, activation='relu'),
    Dropout(0.2),
    Dense(128, activation='relu'),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(16, activation='relu'),
    Dense(1)
])

--- MODEL PERFORMANS SONUÇLARI ---
R-Kare (R2) Skoru: 0.7510
RMSE (Kök Ortalama Kare Hatası): 1.1819
MAE (Ortalama Mutlak Hata): 0.7609
Model eğitimi tamamlandı. Süre: 1221.33 saniye.
"""

```

"""

```
model = Sequential([
    Input(shape=(4,)),
    Dense(256, activation='relu'),
    BatchNormalization(),
    Dropout(0.2),
    Dense(128, activation='relu'),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(16, activation='relu'),
    Dense(1)
])
```

--- MODEL PERFORMANS SONUÇLARI ---

R-Kare (R2) Skoru: 0.7355

RMSE (Kök Ortalama Kare Hatası): 1.2202

MAE (Ortalama Mutlak Hata): 0.7848

Model eğitimi tamamlandı. Süre: 847.29 saniye.

"""

"""

```
model = Sequential([
    Input(shape=(4,)),
    Dense(256, activation='relu'),
    BatchNormalization(),
    Dropout(0.2),

    Dense(128, activation='relu'),
    BatchNormalization(),
    Dropout(0.2),

    Dense(64, activation='relu'),
    BatchNormalization(),

    Dense(32, activation='relu'),
```

```
Dense(16, activation='relu'),
Dense(1)
])
```

--- MODEL PERFORMANS SONUÇLARI ---

R-Kare (R2) Skoru: 0.6998

RMSE (Kök Ortalama Kare Hatası): 1.2985

MAE (Ortalama Mutlak Hata): 0.8387

Model eğitimi tamamlandı. Süre: 1082.89 saniye.

""""

""""

3. Model Yapısı (Girdi sayısı 4)

```
model = Sequential([
    Input(shape=(4,)),
    Dense(256, activation='leaky_relu'),
    Dropout(0.2),
    Dense(128, activation='leaky_relu'),
    Dense(64, activation='leaky_relu'),
    Dense(32, activation='leaky_relu'),
    Dense(16, activation='leaky_relu'),
    Dense(1)
])
```

--- MODEL PERFORMANS SONUÇLARI ---

R-Kare (R2) Skoru: 0.7467

RMSE (Kök Ortalama Kare Hatası): 1.1922

MAE (Ortalama Mutlak Hata): 0.7841

Model eğitimi tamamlandı. Süre: 856.80 saniye.

""""

""""

```
model = Sequential([
```

```
Input(shape=(4,)),
Dense(256, activation='elu'),
Dropout(0.2),
Dense(128, activation='elu'),
Dense(64, activation='elu'),
Dense(32, activation='elu'),
Dense(16, activation='elu'),
Dense(1)
])
```

--- MODEL PERFORMANS SONUÇLARI ---

R-Kare (R2) Skoru: 0.7569
RMSE (Kök Ortalama Kare Hatası): 1.1679
MAE (Ortalama Mutlak Hata): 0.7614
Model eğitimi tamamlandı. Süre: 1437.48 saniye.
""""

""""

```
model = Sequential([
    Input(shape=(4,)),
    Dense(256, activation='gelu'),
    Dropout(0.2),
    Dense(128, activation='gelu'),
    Dense(64, activation='gelu'),
    Dense(32, activation='gelu'),
    Dense(16, activation='gelu'),
    Dense(1)
])
```

--- MODEL PERFORMANS SONUÇLARI ---

R-Kare (R2) Skoru: 0.7641
RMSE (Kök Ortalama Kare Hatası): 1.1503
MAE (Ortalama Mutlak Hata): 0.7386
Model eğitimi tamamlandı. Süre: 657.99 saniye.

--- MODEL PERFORMANS SONUÇLARI ---

R-Kare (R2) Skoru: 0.7596

RMSE (Kök Ortalama Kare Hatası): 1.1611

MAE (Ortalama Mutlak Hata): 0.7529

Model eğitimi tamamlandı. Süre: 603.18 saniye.

""""

```
from tensorflow.keras.optimizers import Adam
```

```
from tensorflow.keras.callbacks import ReduceLROnPlateau
```

```
optimizer = Adam(learning_rate=0.001)
```

```
model.compile(optimizer=optimizer, loss='mse', metrics=['mae'])
```

```
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2, patience=5, min_lr=0.00001)
```

```
early_stop = EarlyStopping(  
    monitor='val_loss',  
    patience=20,  
    restore_best_weights=True  
)
```

```
start_time = time.time()
```

```
history = model.fit(  
    X_train_scaled, y_train_scaled,  
    epochs=300,  
    batch_size=32,  
    validation_split=0.1,  
    callbacks=[reduce_lr, early_stop],  
    verbose=1  
)
```

```
end_time = time.time()
```

```
training_time = end_time - start_time
```

```
# 5. Kayıt
```

```
model.save('model.keras')
```

```
joblib.dump(scaler_X, 'scaler_X.pkl')
```

```
joblib.dump(scaler_y, 'scaler_y.pkl')
```

```
# 6. Performans Değerlendirme
```

```
y_pred_scaled = model.predict(X_test_scaled)
```

```
y_pred = scaler_y.inverse_transform(y_pred_scaled).flatten() # Flatten ile 1D yapıyoruz
```

```
y_true = y_test.flatten() if hasattr(y_test, 'flatten') else y_test
```

```
r, _ = pearsonr(y_true, y_pred)
```

```
r2_pearson = r**2
```

```
mae = mean_absolute_error(y_true, y_pred)
```

```
rmse = np.sqrt(mean_squared_error(y_true, y_pred))
```

```
print("\n--- MODEL PERFORMANS SONUÇLARI ---")
```

```
print(f"R-Kare (R2) Skoru: {r2_pearson:.4f}")
```

```
print(f"RMSE (Kök Ortalama Kare Hatası): {rmse:.4f}")
```

```
print(f"MAE (Ortalama Mutlak Hata): {mae:.4f}")
```

```
print(f"Model eğitimi tamamlandı. Süre: {training_time:.2f} saniye.")
```

```
# 7. Görselleştirme
```

```
plt.plot(history.history['loss'], label='Eğitim Kaybı')
```

```
plt.plot(history.history['val_loss'], label='Doğrulama Kaybı')
```

```
plt.title('4 Parametrel Model Eğitim Süreci')
```

```
plt.legend()
```

```
plt.show()
```

Ek-8: Python LightGBM Model Kodu

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, mean_absolute_error,
mean_absolute_percentage_error
import numpy as np
import lightgbm as lgb
import time
from scipy.stats import pearsonr
import mysql.connector

# 1. Veri Çekme (MySQL)
def get_data():
    db_config = {
        'host': 'localhost',
        'user': 'root',
        'password': '1234',
        'database': 'tez'
    }

    query = """
    SELECT Date, Longitude, Latitude, CloudCoverIndex, DayLength, MONTH(Date) as Month,
    SolarRadiation
    FROM View_AllDatas_With_NearestNeighbor
    """

    conn = mysql.connector.connect(**db_config)
    df = pd.read_sql(query, conn)
    conn.close()
    return df

print("Veritabanından veriler okunuyor...")

# 2. Veri Hazırlığı
df = get_data()
```

```
df['DayOfYear'] = pd.to_datetime(df['Date']).dt.dayofyear
```

```
if df is not None and not df.empty:
```

```
# --- 2. VERİ ÖN İŞLEME VE AYIRMA ---
```

```
# Özellikler (X) ve Hedef (y) değişkenlerini tanımlama
```

```
FEATURES = ['CloudCoverIndex', 'DayLength', 'Longitude', 'Latitude', 'DayOfYear', 'Month']
```

```
TARGET = 'SolarRadiation'
```

```
X = df[FEATURES]
```

```
y = df[TARGET]
```

```
# Veri setini eğitim ve test olarak ayırma
```

```
test_size = 0.1
```

```
X_train, X_test, y_train, y_test = train_test_split(
```

```
    X, y, test_size=test_size, random_state=42
```

```
)
```

```
print(f"\nModel Eğitimi için {len(X_train)} satır, Test için {len(X_test)} satır ayrıldı.")
```

```
# --- 3. LIGHTGBM MODELİNİN EĞİTİMİ ---
```

```
print("\nLightGBM Modeli Eğitiliyor...")
```

```
start_time = time.time()
```

```
# LightGBM parametreleri
```

```
lgb_params = {
```

```
    'objective': 'regression',
```

```
    'metric': 'rmse',
```

```
    'n_estimators': 2000,
```

```

'learning_rate': 0.03,

'num_leaves': 31,
'max_depth': -1,

'feature_fraction': 0.9,
'bagging_fraction': 0.8,
'bagging_freq': 5,

'min_data_in_leaf': 20,

'n_jobs': -1,
'seed': 42
}

lgb_model = lgb.LGBMRegressor(**lgb_params)

lgb_model.fit(
    X_train, y_train,
    eval_set=[(X_test, y_test)],
    eval_metric='rmse',
    callbacks=[lgb.early_stopping(100, verbose=False)]
)

end_time = time.time()
training_time = end_time - start_time
print(f"Model eğitimi tamamlandı. Süre: {training_time:.2f} saniye.")

MODEL_FILENAME = 'model.txt'
lgb_model.booster_.save_model(MODEL_FILENAME)
print(f"LightGBM Modeli başarıyla kaydedildi: {MODEL_FILENAME}")

# --- 4. MODEL PERFORMANSININ DEĞERLENDİRİLMESİ ---
y_pred = lgb_model.predict(X_test)
# Pearson R-Kare (r2) Hesaplaması
y_true_flat = np.array(y_test).flatten()
y_pred_flat = np.array(y_pred).flatten()

```

```

r, _ = pearsonr(y_true_flat, y_pred_flat)
r2_pearson = r**2

rmse = np.sqrt(mean_squared_error(y_true_flat, y_pred_flat))
mae = mean_absolute_error(y_true_flat, y_pred_flat)

print(f"\n--- LIGHTGBM BİLİNEAR MODEL SONUÇLARI ---")
print(f"Pearson R-Kare (R2): {r2_pearson:.4f}")
print(f"RMSE (Kök Ortalama Kare Hatası): {rmse:.4f}")
print(f"MAE (Ortalama Mutlak Hata): {mae:.4f}")
print(f"Eğitim Süresi: {training_time:.2f} saniye.")

import matplotlib.pyplot as plt
ax = lgb.plot_importance(lgb_model, importance_type='gain')
# Üst başlık
plt.title("Öznitelik Önem Düzeyi")
# Sol (Y eksen) başlık
plt.ylabel("Öznitelikler")
# Alt (X eksen) başlığını kaldır
plt.xlabel("")
plt.show()

"""
Model Eğitimi için 135047 satır, Test için 15006 satır ayrıldı.
LightGBM Modeli Eğitiliyor...
Model eğitimi tamamlandı. Süre: 5.51 saniye.
LightGBM Modeli başarıyla kaydedildi: model.txt

--- LIGHTGBM BİLİNEAR MODEL SONUÇLARI---
Pearson R-Kare (R2): 0.8566
RMSE (Kök Ortalama Kare Hatası): 0.8998
MAE (Ortalama Mutlak Hata): 0.6191
Eğitim Süresi: 5.51 saniye.
"""

```