

**GÜNEŞ IŞINIMI TAHMİNİ İÇİN GÖRÜNTÜ İŞLEME TABANLI YENİ BİR
YAKLAŞIM**

YÜKSEK LİSANS TEZİ

Ardan Hüseyin EŞLİK

Danışman

Dr. Öğr. Üyesi Emre AKARSLAN

İkinci Danışman

Prof. Dr. Fatih Onur HOCAOĞLU

YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI

Aralık 2021

Bu tez çalışması 20.FENBİL.25 numaralı proje ile AKÜ-BAP tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

GÜNEŞ IŞINIMI TAHMİNİ İÇİN GÖRÜNTÜ İŞLEME TABANLI
YENİ BİR YAKLAŞIM

Ardan Hüseyin EŞLİK

Danışman

Dr. Öğr. Üyesi Emre AKARSLAN

İkinci Danışman

Prof. Dr. Fatih Onur HOCAOĞLU

YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI

Aralık 2021

ÖZET

Yüksek Lisans Tezi

GÜNEŞ IŞINIMI TAHMİNİ İÇİN GÖRÜNTÜ İŞLEME TABANLI YENİ BİR YAKLAŞIM

Ardan Hüseyin EŞLİK

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Yenilenebilir Enerji Sistemleri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Emre AKARSLAN

İkinci Danışman: Prof. Dr. Fatih Onur HOCAOĞLU

Güneş kaynağının kesikli ve değişken yapısı, enerjinin verimli bir şekilde kullanımını oldukça zorlaştırmaktadır. Bu sıkıntıların üstesinden gelebilmek ve güneş enerjisinden etkin bir şekilde faydalanabilmek amacıyla güneş ışıınımı tahmini gibi günümüze kadar farklı birçok yöntem kullanılmıştır. Bu çalışmada, gün içinde oluşan bulut hareketlerini takip ederek gelecekte gerçekleşecek bulut hareketlerini tahmin eden, ardından elde edilen bulut hareketi tahmini ve atmosfer dışı güneş ışıınımı verilerin kullanılmasıyla güneş ışıınımı tahmini gerçekleştiren derin öğrenme yaklaşımı geliştirilmiştir. Bu kapsamda, Afyon Kocatepe Üniversitesi Güneş ve Rüzgâr Uygulama ve Araştırma Merkezine kurulan deney düzeneği aracılığıyla belirli aralıklarda toplanan gökyüzü görüntüleri ve ışıınım verileri kullanılmıştır. Sıralı gökyüzü görüntülerinde bulut hareketleri Shi-Tomasi ve Lucas-Kanade yöntemleri kullanılarak takip edilmiştir. Görüntüler üzerinde bulut, gökyüzü, güneş tespitleri ise kırmızı/mavi oranı ve K-means kümeleme yönteminden oluşan hibrit bir tespit yaklaşımıyla gerçekleştirilmiştir. Son olarak, 5 dakikalık zaman ufku için 10 saniye çözünürlüklü güneş ışıınımı tahminleri gerçekleştirilmiş ve yaklaşımın performansı test edilmiştir.

2021, xi + 85 sayfa

Anahtar Kelimeler: Güneş Işıınımı Tahmini, Bulut Hareketi Tahmini, Bulut Hareketi Takibi, Görüntü İşleme, Derin Öğrenme, Uzun Kısa Süreli Bellek

ABSTRACT

M.Sc. Thesis

A NEW IMAGE-PROCESSING BASED APPROACH FOR SOLAR RADIATION FORECASTING

Ardan Hüseyin EŞLİK

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Electrical Engineering

Supervisor: Asst. Prof. Emre AKARSLAN

Co-Supervisor: Prof. Fatih Onur HOCAOĞLU

The intermittent and variable nature of the solar source makes it very difficult to use energy efficiently. In order to overcome these problems and benefit from solar energy effectively, many different methods such as solar radiation estimation have been used until today. In this study, a deep learning approach has been developed that predicts future cloud movements by tracking the cloud movements that occur during the day and then performs solar radiation forecasting using the obtained cloud movement forecast and extraterrestrial solar radiation data. In this context, sky images and radiation data collected at specific intervals through the experimental setup established at Afyon Kocatepe University Sun and Wind Application and Research Center are used. Cloud motions in sequential sky images are followed using Shi-Tomasi and Lucas-Kanade methods. Cloud, sky, and sun detections on the images are performed with a hybrid detection approach consisting of red/blue ratio and K-means clustering method. Finally, solar radiation estimates with a resolution of 10 seconds for the time horizon of 5 minutes are performed, and the performance of the approach is tested.

2021, xi + 85 pages

Keywords: Solar Radiation Prediction, Cloud Motion Prediction, Cloud Motion Tracking, Image Processing, Deep Learning, Long Short Term Memory

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu katkılarından dolayı tez danışmanım Dr. Öğr. Üyesi Emre AKARSLAN'a ve ikinci tez danışmanım Prof. Dr. Fatih Onur HOCAOĞLU'na, her konuda öneri ve eleştirileriyle yardımlarını gördüğüm tüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu tez çalışmasını 20.FEN.BİL.25 proje ile AKÜ-BAP tarafından destekleyen Afyon Kocatepe Üniversitesine teşekkürlerimi sunarım.

Tez çalışmam süresince yanımda olan aileme özellikle de sevgili anneme ve babama teşekkürü bir borç bilirim. Hayatımın her alanında olduğu gibi, tez çalışmamı hazırlarken de her aşamada bana yardımcı olan, sabır gösterip bana katlanan ve yanımda olan nişanlım Şeyma'ya sonsuz teşekkür ederim.

Ardan Hüseyin EŞLİK

Afyonkarahisar 2021

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ.....	x
RESİMLER DİZİNİ	xi
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	5
2.1 Doğrusal ve Doğrusal Olmayan Yöntemleri Kullanan Çalışmalar	5
2.2 Uydu Görüntülerini Kullanan Çalışmalar	7
2.3 Makine Öğrenmesi Yöntemleri Kullanılan Çalışmalar	8
2.4 Hibrit Yöntemler Kullanılan Çalışmalar.....	10
2.5 Tüm Gökyüzü Görüntüleyicilerinin (ASI) Kullanıldığı Çalışmalar	15
3. MATERYAL ve METOT	19
3.1 Kurulan Deney Düzenegi.....	19
3.1.1 Güneş Işınımının Ölçülmesi	20
3.1.2 Gökyüzü Görüntülerinin Toplanması	22
3.2 Bulut Hareketi Takibi	24
3.2.1 Takip Edilecek Öznitelik Noktalarının Bulunması.....	24
3.2.2 Öznitelik Noktalarının Takibi.....	27
3.3 Güneş ve Bulut Tespiti	30
3.3.1 Kırmızı/Mavi Oranı ile Bulut Tespiti	30
3.3.2 K-means Kümeleme Yöntemi ile Bulut Tespiti	31
3.3.3 Güneş Tespiti	32
3.4 Bulut Hareketi Tahmini	34
3.5 Güneş Işınımı Tahmini	34
4. BULGULAR	39

4.1 Bulut Hareketi Takibinin Gerçekleştirilmesi	40
4.1.1 Kullanılan Gökyüzü Görüntüleri	40
4.1.2 Öznitelik Noktalarının Tespitinin Gerçekleştirilmesi	41
4.1.3 Öznitelik Noktalarının Takibinin Gerçekleştirilmesi	43
4.1.4 Bulut Ortalama Hız ve Yönlerinin Hesaplanması	44
4.2 Bulut, Gökyüzü ve Güneş Tespitlerinin Gerçekleştirilmesi	46
4.2.1 Bulut ve Gökyüzü Tespiti	46
4.2.2 Güneş Tespiti ve Güneş Önü Kapalılık/Açıklık Kontrolünün Gerçekleştirilmesi	53
4.2.3 Güneş Yakını Bulut ve Gökyüzü Tespitinin Gerçekleştirilmesi	56
4.3 Bulut Hareketi Tahmininin Gerçekleştirilmesi	60
4.4 Güneş Işınımı Tahmininin Gerçekleştirilmesi	68
4.4.1 Ağın Eğitimi için Gerekli Verilerin Hazırlanması	68
4.4.2 Tahmin Modelinin Oluşturulması ve Eğitiminin Gerçekleştirilmesi	70
4.4.3 Kullanılan Hata Metrikleri	72
4.4.4 Tahmin Modelinin Test Edilmesi	73
5. SONUÇ ve ÖNERİLER	75
6. KAYNAKLAR	78
ÖZGEÇMİŞ	84

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

m^2	Metrekare
V	Volt
W	Watt
MW	Megawatt
$^{\circ}C$	Santigrad Derece
<	Küçüktür
>	Büyüktür
μ	Mikro
g	Gram
%	Yüzde
r^2	Açıklayıcılık Katsayısı (r^2 Score)

Kısaltmalar

AKÜ	Afyon Kocatepe Üniversitesi
ANFİS	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System)
ANN	Yapay Sinir Ağları (Artificial Neural Networks)
ARIMA	Bütünleşik Otoregresif Hareketli Ortalama (Autoregressive Integrated Moving Average)
ARMA	Otoregresif Hareketli Ortalamalar Modeli (Autoregressive Moving Average Model)
ASI	Tüm Gökyüzü Görüntüleyicileri (All Sky Imagers)
BARTSM	Bayesian Otomatik Regresif Zaman Serisi Modeli (Bayesian Autoregressive Time Series Model)
BDT	Arttırılmış Karar Ağacı (Boosted Decision Tree)
BI	Parlaklık İndisi
BNN	Bayes Sinir Ağı (Bayesian Neural Network)
BP-ANN	Geri Beslemeli Yapay Sinir Ağları (Back Propagation Artificial Neural Network)
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
DHR	Dinamik Harmonik Regresyon (Dynamic Harmonic Regression)
DN	Yoğun Ağ (Dense Network)
EEMD	Grupsal Ampirik Kip Ayırımı (Ensemble Empirical Mode Decomposition)
ELM	Aşırı Öğrenme Makinesi (Extreme Learning Machine)
ELMAN	Elman Sinir Ağı (Elman Neural Network)
ESRA	Avrupa Güneş Radyasyonu Atlası (European Solar Radiation Atlas)
ETS	Üstsel Eğilim Düzeltme (Exponential Trend Smoothing)
FL	Bulanık Mantık (Fuzzy Logic)
GARCH	Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (Generalized Autoregressive Conditional Heteroskedasticity)
GÜRAM	Güneş ve Rüzgâr Uygulama ve Araştırma Merkezi

Kısaltmalar (Devam)

HSV	Renk özü, Doygunluk, Parlaklık Renk Uzayı (Hue, Saturation, Value Color Space)
KELM	Çekirdek Tabanlı Aşırı Öğrenme Makinesi (Kernel Extreme Learning Machine)
LAB	Değer, Tonlama Doygunluk Renk Uzayı (Value, Tone, Saturation Color Space)
LLSR	Doğrusal En Küçük Kareler Regresyon (Linear Least Square Regression)
LPF	Doğrusal Tahmin Filtresi (Linear Prediction Filter)
LSTM	Uzun/Kısa Süreli Bellek (Long Short Term Memory)
MAE	Mutlak Hata Kriteri (Mean Absolute Error)
MABE	Ortalama Mutlak Sapma Hatası (Mean Absolute Bias Error)
MAPE	Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error)
MARE	Ortalama Mutlak Göreceli Hata (Mean Absolute Relative Error)
MBE	Ortalama Sapma Hatası (Mean Bias Error)
MD-LPF	Çok Boyutlu Doğrusal Tahmin Filtreleri (Multi Dimensional Linear Prediction Filter)
ML-ANN	Çok Katmanlı İleri Beslemeli Sinir Ağı (Multilayer Feed-Forward Artificial Neural Network)
MLP	Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
MS-MEMD	Çok Aşamalı Çok Değişkenli Ampirik Mod Ayrıştırma (Multi Stage - Multivariate Empirical Mode Decomposition)
NAR	Doğrusal Olmayan Otoregresif Ağ (Nonlinear Autoregressive Neural Networks)
NEA	Ulusal Çevre Ajansı (National Environment Agency)
nRMSE	Normalleştirilmiş Ortalama Kare Hatası (Normalized Root Mean Square Error)
PM	Süreklilik Modeli (Persistence Model)
RBF-ANN	Radyal Tabanlı Fonksiyon Sinir Ağları (Radial Basis Function Neural Networks)
RF	Rassal Orman (Random Forest)
RGB	Kırmızı, Yeşil, Mavi Renk Uzayı (Red, Green, Blue Color Space)
RM	Regresyon Modeli (Regression Model)
RMSE	Ortalama Hata Karekökü (Root Mean Square Error)
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SI	Gökyüzü İndisi
SVC	Destek Vektör Sınıflandırıcısı (Support Vector Classifier)
SVR	Destek Vektör Regresyonu (Support Vector Regression)
TD-ANN	Zaman Gecikmeli Yapay Sinir Ağları (Time Delay Neural Networks)
WA	Dalgacık Analizi (Wavelet Analysis)

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 Türkiye'nin yıllara göre kurulu güç grafiği (İnt. Kyn. 1)	1
Şekil 1.2 20 Eylül 2021 tarihi gün içi güneş ışıınım değeri değışim grafiği	2
Şekil 3.1 3 Eylül 2021 tarihinde, kurulan deney düzeneđi yardımıyla toplanan 10'ar saniyelik güneş ışıınımı zaman serisi.	22
Şekil 3.2 Tekrarlayan sinir ađının kapalı gösterimi (İnt. Kyn. 5).	36
Şekil 3.3 Tekrarlayan sinir ađının açık gösterimi (İnt. Kyn. 5).....	36
Şekil 3.4 Standart RNN modül yapısı (İnt. Kyn. 5).	37
Şekil 3.5 LSTM modül yapısı (İnt. Kyn. 5).	37
Şekil 4.1 Geliştirilen yaklaşıma ait akış şeması.	39
Şekil 4.2 9 Eylül 2021 tarihinde deney düzeneđi kullanılarak elde edilen gökyüzü görüntüsü örnekleri.....	41
Şekil 4.3 İki farklı gökyüzü görüntüsünde tespit edilen öznitelik noktalarının gösterimi.	42
Şekil 4.4 İki farklı gökyüzü görüntüsünde tespit edilen öznitelik noktalarının takibinin gerçekleştirilmesi.....	44
Şekil 4.5 Gerçekleştirilen bulut hareketi takibi (solda), tespit edilen tehlikeli doğrular (sağda).	46
Şekil 4.6 Kırmızı/mavi oranı yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler.	47
Şekil 4.7 K-means kümeleme yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler.	48
Şekil 4.8 K-means kümeleme yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler ve hibrit sınıflandırma yaklaşımı sonuçları.	50
Şekil 4.9 Kırmızı/mavi oranı yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler ve hibrit sınıflandırma yaklaşımı sonuçları.	50
Şekil 4.10 Güneşin bulut tespiti aşamasında oluşturduđu bozucu etkiler (güneşin bulut olarak tespit edilmesi).	52
Şekil 4.11 Gökyüzü görüntüleri üzerinde bulunan ve tespit edilen güneş konumları....	54
Şekil 4.12 Güneş önü kapalılık/açıklık kontrolünün gerçekleştirilmesi.....	56
Şekil 4.13 Gökyüzü görüntülerinde güneş yakını bulut tespiti aşamaları.	58
Şekil 4.14 Az bulutlu gökyüzü durumlarında güneş çevresinde gerçekleştirilen sınıflandırma aşamalarına ait örnekler.	59
Şekil 4.15 Çok bulutlu gökyüzü durumlarında güneş çevresinde gerçekleştirilen sınıflandırma aşamalarına ait örnekler.	60
Şekil 4.16 İstenmeyen kısımların atılması için kullanılan tahmin maskesi.	61

Şekil 4.17 Sıralı 6 gökyüzü görüntüsü kullanılarak gerçekleştirilen bulut hareketi tahminine ait tüm süreçler.	63
Şekil 4.18 Çok az bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.	64
Şekil 4.19 Az bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.	65
Şekil 4.20 Orta seviye bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.	65
Şekil 4.21 Çok bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.	66
Şekil 4.22 9 Eylül 2021 tarihi için gerçekleştirilen bulut hareketi tahminleri.	67
Şekil 4.23 20 Eylül 2021 10:00-16:00 aralığında ölçülen güneş ışıınımı değerleri.	69
Şekil 4.24 9 Eylül 2021 10:00-16:00 aralığında ölçülen güneş ışıınımı değerleri.	69
Şekil 4.25 Hatanın iterasyona bağlı değişimi.	71
Şekil 4.26 Gerçek güneş ışıınımı değerleri ile model tahminlerinin karşılaştırılması. ...	73
Şekil 4.27 Tahmin ve gerçek değerlerle birlikte bulut hareket değerlerinin gösterimi. .	74

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Kipp&Zonen CMP6 piranometre teknik özellikleri (İnt. Kyn. 2).	21
Çizelge 3.2 Canon EOS 80D dijital fotoğraf makinesi teknik özellikleri (İnt. Kyn. 3). ..	22
Çizelge 4.1 GoodFeaturesToTrack() fonksiyonu parametre değerleri.....	42
Çizelge 4.2 CalcOpticalFlowPyrLK() fonksiyonu parametre değerleri.....	43
Çizelge 4.3 Güneş tespitinde kullanılan renk uzayı parametreleri ve değerleri.....	53
Çizelge 4.4 HoughCircles() fonksiyonunda kullanılan parametreler ve değerleri.....	55
Çizelge 4.5 Güneş önü tamamen kapalı değerlendirmesinin gerçekleştirilmesi.....	57
Çizelge 4.6 Gerçekleştirilen tahmin için hesaplanan hata metrikleri.....	74



RESİMLER DİZİNİ


	Sayfa
Resim 3.1 Afyon Kocatepe Üniversitesi Güneş ve Rüzgâr Uygulama ve Araştırma Merkezi çatısına yerleştirilmiş dijital fotoğraf makinesi.	20
Resim 3.2 Afyon Kocatepe Üniversitesi Güneş ve Rüzgâr Uygulama ve Araştırma Merkezinde bulunan piranometre.	20



1. GİRİŞ


Enerji, ülkelerin sosyal ve ekonomik olarak gelişiminde büyük rol oynayan, gündelik hayatın vazgeçilmez bileşenlerinden biridir. Gelişen teknoloji, artan nüfus ile birlikte enerji ihtiyacı tüm dünyada hızla artmaktadır. Artan enerji ihtiyacıyla birlikte doğal enerji kaynakları da hızla tükenmektedir. Enerji ihtiyacının büyük bir bölümünü karşılayan fosil yakıtların sınırlı olmasının yanında, küresel ısınma, hava kirliliği, yüksek karbon emisyon oranları, iklim değişikliği gibi çevresel zararları da beraberinde getirmesi, temiz ve sürdürülebilir enerji kaynaklarına duyulan ihtiyacı net bir şekilde ortaya koymaktadır.

Ülkemiz, enerji bakımından dışa bağımlılığı yüksek bir ülkedir. Dışa bağımlılığımızın azaltılabilmesi için yerli ve yenilenebilir enerji kaynaklarının kullanımının yaygınlaştırılması ve uygun mühendislik sistemlerinin geliştirilmesi gerekmektedir. Bu noktada ülkemizin coğrafi konumu nedeniyle güneş enerjisi bakımından sahip olduğu yüksek potansiyelin değerlendirilmesi büyük önem arz etmektedir. Son yıllarda yapılan yatırımlar ve çalışmalar ile desteklenen güneş enerjisi uygulamaları büyük hız kazanmıştır. Yakın gelecekte bu konuda dünyanın önde gelen ülkeleri arasına girme hedefi bulunan ülkemizde uygulamaların artarak devam etmesi beklenmektedir. Şekil 1.1’de Türkiye’nin yıllara göre kurulu güç değişimleri görülebilmektedir.



Şekil 1.1 Türkiye'nin yıllara göre kurulu güç grafiği (İnt. Kyn. 1).

Güneş enerjisi uygulamalarının hızla yaygınlaşmasına karşın, güneş kaynağının kesikli ve değişken bir yapıya sahip olması, enerjinin verimli bir şekilde kullanımını oldukça zorlaştırmaktadır. Dolayısıyla, güneş enerjisinden etkin bir şekilde faydalanabilmek için bu sıkıntıların üstesinden gelinmesi gereklidir. Güneş enerjisini elektrik enerjisine dönüştürmekte kullanılan fotovoltaiik panellerin anlık güç çıkışı, büyük oranda güneş ışıınım değerine bağlıdır. Bir bölgenin yüzeyinde ölçülen güneş ışıınımı değeri, coğrafi konum, mevsim, bulut örtüsü, havadaki kir parçacıkları gibi faktörlere bağlı olarak değişmektedir. Bu faktörlerin arasında, bulut örtüsü, güneş kaynağının dengesiz ve aralıklı yapıda bulunmasına neden olan en temel faktörlerden biridir (Cheng ve Yu 2015). Bir bulut veya bulut kümesinin güneşin önünü kapatmasıyla, güneş ışıınım değeri kısa sürede ani değişimler gösterebilmektedir. Şekil 1.2’de görülebileceği üzere bulutlu bir havada ışıınım değeri bir dakikadan kısa bir sürede sıfıra yakın değerlere düşebilmekte ve tekrar eski değerlerine dönebilmektedir.



Şekil 1.2 20 Eylül 2021 tarihi gün içi güneş ışıınım değeri değişim grafiği.

Zemin seviyesindeki ışıınım değerinin göstermiş olduğu bu yüksek değişkenlikler, güneş enerjisi santrallerinden elektrik şebekesine aktarılacak gücün entegre edilmesini zorlaştırmakta ve entegrasyon maliyetlerini arttırmaktadır. Güç sistemi operatörlerinin, güvenilirliği korurken güneş enerjisi üretim seviyelerini başarılı bir şekilde entegre edebilmeleri ve kurulması planlanan yeni güneş enerji sistemlerinin optimizasyon, tasarım, performans değerlendirmelerini gerçekleştirebilmeleri için güneş ışıınımı değerinin bilinmesine büyük oranda gereksinim duyulmaktadır. Verimli bir tahmin

aracının kullanılmasıyla güneş ışıını deęeri geręe en yakın oranda tahmin edilebilecek, bu sayede g sistemi operatrlerinin retimi planlayabilmesi, yklerde ve g ıkıřlarındaki deęiřiklikleri ekonomik olarak ynetebilmesi saęlanabilecektir (Watetakarn ve Premrudeepreechacharn 2015). Bu amalar iin, dakikalar ve saatlerden, birkaç gn ilerisine kadar deęiřebilen farklı zaman dilimlerinde güneş ışıını tahminlerine ihtiya duyulmaktadır. Kısa vadeli tahminler konsantre güneş enerjisi santrallerinin ynetimi, gn ii elektrik piyasalarına katılmak ve rampa (ışıını deęerinde ani ve byk dř) olaylarını tahmin edebilmek iin zellikle nemlidir. Bu nedenle bařarılı güneş ışıını tahmin yntemlerinin geliřtirilmesi, güneş enerjisi kullanımının artması ve řebeke entegrasyonu iin kilit bir unsur haline gelmiřtir (Rodríguez-Benítez vd. 2020).

Gnmze kadar güneş ışıını tahmini iin farklı birok yntem ve yaklařım kullanılmıřtır. Bu yntem ve yaklařımlar arasında sayısal hava tahminleri veya uydu bulut gzlem bilgilerinin kullanımı olduka yaygındır. İlgili yntemlerin kullanılmasıyla geniř alanlar ve uzun zaman lekleri iin bařarılı tahminler gerekleřtirilmektedir. Ancak, bu alan ve zaman leklerindeki tahminler geniř alanlar ve uzun sreleri kapsaması nedeniyle güneş ışıınının yksek frekans dalgalanmaları hakkında bilgi saęlamak iin yetersiz kalmaktadır. rneęin belirli bir blgenin genel alanının gneřli bir gne sahip olacaęı tahmin edilirken, güneş ışııı zaman zaman bulut rts tarafından kesintilere uęrayabilir. Bu kesintiler, o blgede kurulu herhangi bir güneş santralinin enerji retim seviyesini etkileyebilir. Dolayısıyla, sayısal hava veya uydu bulut gzlem tahminlerine oranla daha kısa vadeli, kesin bir alana zg ve yerinde tahminlere ihtiya duyulmaktadır. Bu gereksinimler arařtırmacıları gkyz grntlerini yakalayan, bulut ve güneş bilgilerinin ayrıntılı bir řekilde srece dahil edilebildięi Tm Gkyz Grntleyicileri'ne (ASI) sahip alıřmalara ynlendirmiřtir. Bu sistemlerin gkyz grntlerini geniř aılı bir řekilde yakalayabilme yetenekleri sayesinde yerleřtirildikleri konuma ait yksek znrlkl bilgilere eriřmek mmkn olmaktadır.

Bu tez alıřmasında, gn ii bulut hareketlerini takip ederek gelecekte oluřacak bulut hareketlerini tahmin eden, ardından elde edilen bulut tahminlerini kullanarak kısa vadeli güneş ışıını tahminleri gerekleřtiren bir derin ęrenme yaklařımı geliřtirilmiřtir.

Bu amaç doğrultusunda ilk olarak, bulutların gün içerisindeki konumları ve değişimlerini inceleyebilmek ve güneş ışıınımı verilerini toplayabilmek amacıyla Afyon Kocatepe Üniversitesi (AKÜ) kampüsünde bir deney düzeneği oluşturulmuştur. Kurulan düzenek sayesinde gökyüzü görüntüleri ve güneş ışıınımı verileri belirli aralıklarla toplanmıştır. Elde edilen gökyüzü görüntülerinde bulutları ve güneşi gökyüzünden ayırıştırabilmek için belirli görüntü işleme algoritmaları kullanılmıştır. Ardından, bulutlara ait takibe en uygun öznitelik noktalarının bulunması amacıyla Shi-Thomasi öznitelik seçme algoritması kullanılmıştır. Sıralı görüntüler üzerinde tespit edilen öznitelik noktalarının Lucas-Kanade optik akış yöntemi ile takip edilmesi sonucunda bulutlara ait ortalama hız ve hareket yönü bilgilerine ulaşılmış ve bu bilgiler kullanılarak gelecekte oluşacak bulut hareketleri tahmin edilmiştir. Son olarak, bulut hareketi tahminleri ve atmosfer dışı güneş ışıınımı değerlerinin kullanılmasıyla bir Uzun Kısa Süreli Bellek (LSTM) derin öğrenme modeli oluşturulmuş ve kısa vadeli güneş ışıınımı tahminleri gerçekleştirilmiştir. Geliştirilen güneş ışıınımı tahmin yaklaşımının performansı literatürde kullanılan metriklerle değerlendirilmiş ve ileride yapılacak çalışmalar planlanmıştır.

Tez çalışmasının organizasyonu şu şekilde planlanmıştır: ilk olarak literatür bilgileri başlığı altında literatürde gerçekleştirilen çalışmalara yer verilmiştir. Materyal ve metot başlığı altında; kurulan deney düzeneği, bulut hareketi takibi, güneş ve bulut tespiti, bulut hareketi tahmini ve güneş ışıınımı tahmini aktarılmıştır. Ardından bulgular başlığı altında, gerçekleştirilen deneysel çalışmalar ve bu deneysel çalışmalara ait bulgulara yer verilmiştir. Son olarak sonuç ve öneriler başlığı altında gerçekleştirilen çalışmalara ait değerlendirmeler gerçekleştirilmiş ve önerilerde bulunulmuştur.

2. LİTERATÜR BİLGİLERİ

Bu bölüm kapsamlı bir literatür taraması sunulmakta olup, beş bölümden oluşmuştur. Başlıklarda ele alınan konular ise şunlardır: Bölüm 2.1’de doğrusal ve doğrusal olmayan yöntemleri kullanan çalışmalar, bölüm 2.2’de doğrusal ve doğrusal olmayan yöntemleri kullanan çalışmalar, uydu görüntülerini kullanan çalışmalar, bölüm 2.3’de makine öğrenmesi yöntemleri kullanan çalışmalar, bölüm 2.4’de hibrit yöntemler kullanılan çalışmalar ve son olarak bölüm 2.5’de Tüm Gökyüzü Görüntüleyicilerinin (ASI) kullanıldığı çalışmalar aktarılmıştır.

2.1 Doğrusal ve Doğrusal Olmayan Yöntemleri Kullanan Çalışmalar

Mellit vd. (2006), günlük toplam güneş ışıınımını tahmin etmek için uyarlanabilir bir Dalgacık-Ağ modeli önermişlerdir. Ayrıca, kayıp veri probleminin çözümü için çeşitli yapılar incelemişlerdir. Bu tahmin sürecinde model, gizli birimlere gömülü dalgacık dönüşümü ile uyarlanabilir bir sinir ağı topolojisinden oluşmaktadır. Tahmin sonuçları, yaklaşımın diğer modellere kıyasla daha iyi performansı gösterdiğini ortaya koymuştur.

Moghaddamnia vd. (2009), İngiltere’de atmosfer dışı ışıınım, yağış, hava sıcaklığı ve rüzgâr hızını kullanarak günlük küresel güneş ışıınımını tahmin etmiştir. Tahmini gerçekleştirebilmek için, Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFİS), Çok Katmanlı Algılayıcı (MLP), Elman Sinir Ağı (ELMAN) gibi farklı doğrusal olmayan modeller kullanmış ve modeller arasında bir karşılaştırma sağlamıştır.

Bracale vd. (2013), güç çıkışı olasılık yoğunluk fonksiyonundan bir saat ilerisi için olasılık tahminleri elde etmişlerdir. Bunu oluşturmak için ilk olarak geçmiş verilerden türetilen açıklık indeksi yoğunluk fonksiyonunu oluşturmuşlardır. Ardından, güneş ışıınımını meteorolojik değişkenlerle ilişkilendirmiş ve Bayesian Otomatik Regresif Zaman Serisi Modelini (BARTSM) kullanmışlardır. Böylelikle güneş ışıınımının gelecekteki ortalama değerini tahmin etmişlerdir. Deneyler sonucunda, kış ve yaz mevsimleri için sırasıyla %14,5 ve %18,0’lik Ortalama Mutlak Göreli Hata (OMGH) değerleri elde edilmiştir.

Chen vd. (2013), Bulanık Mantık (FL) ve Yapay Sinir Ağlarına (ANN) dayalı bir güneş ışıınımı tahmin yaklaşımı geliştirmişlerdir. Yaklaşım, gelecekteki gökyüzü koşulları ve sıcaklık bilgilerini Ulusal Çevre Ajansı'ndan (NEA) elde etmekte ve gökyüzü-sıcaklık bilgilerini bulanık kurallara göre farklı bulanık kümeler olarak sınıflandırmaktadır. Güneş ışıınımı tahminleri FL ve ANN'nin birlikte kullanılmasıyla gerçekleştirilmektedir. Yaklaşımın performansı dört farklı senaryo durumu için test edilmiştir. Sonuçlar, önerilen yaklaşımın kullanılmasıyla, ışıınım tahmin sonuçlarının çok daha başarılı olduğunu ortaya koymuştur.

Mecibah vd. (2014), Cezayir'de bulunan altı farklı şehrin aylık ortalama günlük küresel güneş ışıınımını tahmin etmek için bir yaklaşım önermişlerdir. Elde edilen sonuçlar, güneş ışığına dayalı modellerin genellikle ortam sıcaklığına dayalı modellerden daha doğru olduğunu gösteren önceki çalışmaların sonuçlarını doğrulamıştır. Ayrıca altı Cezayir şehri için en iyi performansı kübik ve ikinci dereceden regresyon modelleri ile sağlamışlardır.

Akarşan vd. (2014), güneş ışıınımı tahmini için Çok Boyutlu Doğrusal Tahmin Filtresi (MD-LPF) yaklaşımının kullanılmasını önermiştir. Yaklaşım, ışıınım değerlerini çok boyutlu görüntü biçimlerine çevirerek güneş ışıınımı tahminini gerçekleştirmektedir. Elde edilen sonuçlar daha önce geliştirilmiş olan Doğrusal Tahmin Filtre (LPF) modelleri ve geleneksel yöntemlerle karşılaştırılmıştır. Sonuçlar, önerilen yaklaşımın 2 boyutlu modellere kıyasla %1-30 aralığında daha iyi tahmin doğruluğu sağladığını göstermiştir.

Trapero vd. (2015), Dinamik Harmonik Regresyon (DHR) modelini kullanarak 1-24 saat sonrası için güneş ışıınımı tahmini gerçekleştirmişlerdir. Önerilen model, Süreklilik Modeli (PM), Mevsimsel PM, Üstel Eğilim Düzeltme (ETS) ve Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) modelleriyle karşılaştırılarak performansı incelenmiştir. Gerçekleştirilen değerlendirme sonucunda DHR'nin diğer modellerden daha iyi performans gösterdiği gözlenmiştir.

Yang vd. (2015), Hawaii’de birkaç yüz metre karelik küçük örnek alanındaki gecikmeli zaman serilerini ilişkilendirmek, böylelikle kısa vadeli güneş ışıınımı tahmini gerçekleştirmek için Yoğun Ağ’ı (DN) kullanmışlardır. Parametre seçim yöntemi olarak Lasso Regresyonu uygulanmıştır. Deney sonuçları, süreklilik ve diğer zaman serisi yöntemlerine göre bir gelişme göstermiştir.

Hocaoglu ve Serttas (2017), kısa vadeli saatlik güneş ışıınımı tahmini için Mycielski tabanlı farklı bir yaklaşım önermişlerdir. Bu yaklaşım, güneş ışıınımı verilerinin tarihte kendini tekrar ettiğini varsaymaktadır. Model, kaydedilen saatlik güneş radyasyonu verilerine en benzer geçmiş güneş ışıınımı verilerini bulmaya çalışmaktadır. Birden fazla benzerliğin bulunması durumunda model, son ışıınım değerlerinin bir sonraki değere olan olasılık ilişkilerine göre seçime karar vermektedir. Olasılık ilişkilerinin modellenmesinde Markov zincir modeli benimsenmiş ve kullanılmıştır. Yaklaşımın performansı RMSE, MABE, r^2 hata metrikleri yardımıyla literatürde bulunan diğer modellerle karşılaştırılmıştır. Deney sonuçları, yaklaşımın saatlik güneş ışıınımı tahmininde başarılı bir şekilde kullanılabileceğini göstermiştir.

2.2 Uydu Görüntülerini Kullanan Çalışmalar

Aguiar vd. (2015), Pozo ve Las Palmas’da bulunan iki istasyondan alınan yer ölçüm verileri ve uydu verilerini kullanarak 1 ile 6 saat aralığında değişen zaman ufukları için güneş ışıınımı tahmini gerçekleştiren ANN modeli önermişlerdir. İlk olarak ANN yalnızca geçmiş güneş ışıınımı verileri ile eğitilmiş ve literatürde bulunan hata metrikleri yardımıyla performansı değerlendirilmiştir. Ardından, uydu verileri eğitim sürecine dahil edilmiş ve modelin performansı tekrar incelenmiştir. Değerlendirmeler sonucunda, uydu görüntülerinin eğitim sürecine dahil edildiği modelde %4-5 oranlarında tahmin performansında iyileşmeler gözlenmiştir.

Alonso-Montesinos ve Batlles (2015), uydu görüntülerine dayanarak 15 dakika ila 3 saat arasındaki zaman ufuklarında güneş ışıınımını tahmin etmişlerdir. Bu amaç doğrultusunda, uydu görüntülerinde bulunan bulutları tespit etmek, hareketlerini belirlemek ve güneş ışıınımı tahminini gerçekleştirebilmek için ESRA (European Solar

Radiation Atlas) ve Heliosat-2 yöntemlerini kullanmışlardır. Gökyüzü durumlarını açık, parçalı bulutlu ve kapalı olmak üzere 3 farklı sınıfa ayırmışlardır. Tüm gökyüzü koşulları için %19-21 oranlarında normalleştirilmiş RMSE (nRMSE) değeri elde etmişlerdir.

2.3 Makine Öğrenmesi Yöntemleri Kullanılan Çalışmalar

Al-Shamisi vd. (2013), 1995-2007 yılları arasında Birleşik Arap Emirlikleri Al-Ayn şehrinden toplanan maksimum sıcaklık, rüzgâr hızı, bağıl nem ve güneşlenme süresi verilerini kullanarak günlük ortalama ışıınım değerini tahmin etmişlerdir. Tahmin modeli olarak MLP ve Radyal Tabanlı Fonksiyon Sinir Ağlarını (RBF-ANN) kullanarak performanslarını karşılaştırmışlardır. Gerçekleştirilen deneyler, RBF-ANN modelinin MLP modeline oranla çok daha yüksek doğruluklarda ışıınım tahminleri gerçekleştirilebildiğini ortaya koymuştur.

Renno vd. (2015), İtalya'nın Salerno kentinde bulunan bir deneysel sistemden, 2013 ve 2014 yılları arasında toplanan verileri kullanarak, saatlik güneş ışıınımı tahmini gerçekleştirmişlerdir. ışıınım tahmini için MLP modelini geliştirmişlerdir. Gerçekleştirilen deneyler sonucunda, sırasıyla %5,72, %3,15 ve 0,992'lik MAPE (Ortalama Mutlak Yüzde Hatası), RMSE (Ortalama Hata Kare Kökü) ve r^2 (Açıklayıcılık Katsayısı) hata ölçütü değerlerini elde etmişlerdir. Çalışma neticesinde, MLP ağının farklı meteorolojik koşullar altında, saatlik güneş ışıınımı tahmininde başarılı bir şekilde kullanılabileceği sonucuna ulaşmışlardır.

Shamshirband vd. (2015) Çekirdek Tabanlı Aşırı Öğrenme Makinesi (KELM) kullanarak günlük güneş ışıınımı tahmini gerçekleştirmişlerdir. Modelin oluşturulmasında, 1993-2015 yılları arasında İran'da Bandar Abbas'tan alınan günlük ışıınım, maksimum sıcaklık ve minimum sıcaklık verilerini kullanmışlardır. Elde edilen sonuçlar KELM'in Aşırı Öğrenme Makinesine (ELM) oranla daha etkili, hızlı eğitilebilir ve kolay uygulanabilir olduğunu göstermiştir.

Alzahrani vd. (2017), Kanada'da güneş çiftliğinden elde edilen verileri kullanılarak kısa vadede güneş ışıınımı tahmin etmek için Tekrarlayan Sinir Ağı (RNN) modeli

geliştirmişlerdir. Tahmin sonuçlarını İleri Beslemeli Sinir Ağı ve Destek Vektör Regresyonu (SVR) modellerinden elde edilen sonuçlarla karşılaştırmışlardır. Karşılaştırma sonuçları, RNN modelinin diğer modellerden daha iyi performans gösterdiğini ortaya çıkartmıştır.

Khosravi vd. (2018), iki farklı tür girdi verisi ve farklı tahmin modelleri kullanarak saatlik güneş ışıınımı tahmini gerçekleştirmişlerdir. İlk veri setinde girdi değişkenleri olarak yerel saat, sıcaklık, basınç, rüzgâr hızı ve bağıl nem kullanılmıştır. İkinci veri setinde ise yalnızca geçmiş güneş ışıınımı zaman serisi kullanılmıştır. RBF-ANN, Çok Katmanlı İleri Beslemeli Sinir Ağı (ML-ANN), SVR ve ANFİS yöntemleri ile geliştirilen modeller, her iki veri seti kullanılarak eğitilmiş ve performansları incelenmiştir. Sonuçlar, ilk veri seti kullanılarak eğitimi gerçekleştirilen SVR ve ML-ANN modellerinin güneş ışıınımı tahmininde diğer modellere kıyasla daha başarılı olduğunu göstermiştir.

Qing ve Niu (2018), hava tahmin verilerini kullanarak 1 gün sonrası için saatlik güneş ışıınımı tahminleri gerçekleştiren Uzun/Kısa Süreli Bellek (LSTM) modeli geliştirmişlerdir. Geliştirilen modelin başarısı, Doğrusal En Küçük Kareler Regresyon (LLSR) ve ML-ANN yöntemi sonuçları ile karşılaştırarak analiz edilmiştir. Cape Verde, Santiago adasında toplanan bir veri kümesi üzerinde gerçekleştirilen deneysel sonuçlar, önerilen algoritmanın diğer algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur.

Ayodele vd. (2019), SVR kullanarak Nijerya İbadan kentinde günlük güneş ışıınımını tahmin etmişlerdir. SVR modelinin eğitimini gerçekleştirmeden önce gökyüzü durumlarını K-means Kümeleme Yöntemi kullanarak 4 kümeye ayırmışlardır. 2010-2015 yılları arasında toplanan meteorolojik veriler modelin eğitiminde, 2016-2017 arasında toplananlar ise modelin yeterliliğinin test edilmesinde kullanılmıştır. Modelin performansı, ANN, Angstrom-Prescott ve Otoregresif Hareketli Ortalamalar Modelleri (ARMA) ile karşılaştırılarak incelenmiştir. Deneyler sonucunda, önerilen modelin diğer modellere kıyasla daha iyi tahmin kabiliyetine sahip olduğu ve enerji planlamasında kullanılabileceği belirlenmiştir.

Yu vd. (2019), 1 saat ve 1 gün aralığında deęiřen kısa zaman ölçeklerinde güneř ışıını tahminini gerçekleřtirmek için LSTM tabanlı bir yaklaşım kullanmışlardır. Bulutlu günlerde tahmin doğruluęunu iyileřtirmek için bulutluluk indeksini tahmin sürecine dahil etmişlerdir. Ayrıca bulutluluk durumunu (çok bulutlu veya parçalı bulutlu) K-means kullanarak belirlemişlerdir. Elde edilen saatlik tahmin sonuçlarına göre LSTM'nin RNN'ye göre daha başarılı tahminler gerçekleřtirebildięi sonucuna ulaşmışlardır.

Pang vd. (2020), Alabama, Amerika'da hava istasyonundan toplanan meteorolojik veriler ile RNN ve Geri Beslemeli Yapay Sinir Aęı (BP-ANN) modellerini kullanarak 10 dakika-1 saat aralığındaki zaman ölçeklerinde güneř ışıını tahmini gerçekleřtirmişlerdir. Gerçekleřtirilen deneyler sonucunda, RNN modelinin BP-ANN modeline oranla Ortalama Sapma Hatası (MBE) ve RMSE hata ölçütleri yönünden sırasıyla %47 ve %26 daha iyi sonuçlar elde edebildięini tespit etmişlerdir. Ayrıca, bulut örtüsünün tahmin doğruluęu üzerinde önemli bir etkisi olabileceęi bulunmuřtur.

2.4 Hibrit Yöntemler Kullanılan Çalışmalar

Ji ve Chee (2011), saatlik güneř ışıını tahmin edebilmek için 2 aşamadan oluşan yeni bir hibrit model önermişlerdir. Önerilen modelin ilk aşamasında zaman serisi belirli ön işlemlerden geçirilmektedir. İkinci aşamada ise ARMA ve Zaman Gecikmeli Yapay Sinir Aęı (TD-ANN) modelleri kullanılarak tahmin süreci gerçekleřtirilmektedir. ARMA modelinin zaman serisinin doğrusal bileřeninin modellenmesi, TD-ANN modelinin ise doğrusal olmayan bileřeninin modellenmesi için daha uygun olduęu varsayımına dayanarak oluşturulan Hibrit ARMA-TD-ANN modelinin performansı Singapur'da saatlik küresel güneř ışıını tahmini gerçekleřtirilerek test edilmiştir. Elde edilen istatistiksel göstergeler önerilen ARMA/TD-ANN modelinin tekli ARMA ve TD-ANN modellerinin tahmin sonuçlarına kıyasla daha iyi performans gösterdięini ortaya koymuřtur.

Voyant vd. (2012), Akdeniz bölgesindeki beř farklı alanda saatlik güneř ışıını tahmini gerçekleřtirebilmek için sayısal hava tahmin modeline sahip yapay sinir aęı / otoregresif hareketli ortalama modeli (ANN / ARMA) hibrit modelini önermişlerdir. Önerilen hibrit

modelde söz konusu alanın bulutluluğunun fazla olması durumunda ANN modeli, az olması durumunda ise ARMA modeli kullanılmıştır. Ayrıca, anlık olarak kullanılan modelin yapmış olduğu hata oranı ile bir önceki saat için yapılan tahmindeki hata oranı karşılaştırılmıştır. Hatanın daha düşük çıkması durumunda aynı model ile devam edilmiş, aksi durumda ise diğer tahmin modeline geçiş yapılmıştır. 2002-2008 yılları arasında saatlik olarak ölçülen verilerin ilk dört yılı eğitim için, kalan iki yılı ise test için kullanılmıştır. Sonuçlar, çalışma gerçekleştirilen beş farklı alan için de tekli modellere kıyasla ANN/ARMA hibrit yönteminin daha iyi performans gösterdiğini ortaya koymuştur.

Voyant vd. (2013), ANN/ARMA hibrit modelini kullanarak farklı üç yaklaşım geliştirmişlerdir. İlk yaklaşımda, ilkbahar ve yaz aylarında ARMA modelinin, sonbahar ve kış aylarında ise optimize edilmiş ANN'nin kullanılmasını ele almışlardır. İkinci yaklaşımda ilk yaklaşımdaki kullanımları temel alarak her iki model için mevsimsel analizler gerçekleştirmişlerdir. Üçüncü yaklaşımda ise hangi tahmin modelinin kullanılacağını bir önceki hata değeri baz alınarak belirlenmiştir. Elde edilen on yıllık güneş ışınlamı verisinin ilk dokuz yılı modellerin eğitiminde, kalan bir yıllık veri ise testte kullanılmıştır. Önerilen modelin performansı Akdeniz bölgesinde beş farklı alanda yapılan tahmin sonuçları baz alınarak değerlendirilmiştir. Sonuçlar önerilen hibrit yöntemin karşılaştırılan tüm modellere oranla daha başarılı sonuç elde ettiğini ve tüm mevsimlerde yaklaşık %1'den fazla oranla (sonbaharda %3,4 ve kışın minimumda %0,9) tahmin performansını arttırdığını göstermiştir.

Voyant vd. (2014), tekli ve hibrit tahmin modellerinin performansını incelemişlerdir. Tekli model olarak MLP, ARMA ve PM tercih etmişlerdir. Tercih edilen tekli modellerin farklı birçok kombinasyonu ile hibrit modeller oluşturulmuştur. Oluşturulan hibrit modellerde hangi tekli tahmin modelinin bir sonraki tahmini gerçekleştireceğinin belirlenmesinde bayes kurallarını kullanmışlardır. Modellerin eğitim ve test süreci için 1998-2011 yılları arasında Fransa ulusal meteoroloji organizasyonu tarafından Ajaccio şehri için toplanan saatlik güneş ışınlamı verisini kullanmışlardır. 1998-2009 yılları arasındaki veri eğitim aşamasında kullanılırken, kalan 2 yıllık veri ise test aşamasında kullanılmıştır. Çalışmaları sonucunda bir gün sonrası için yapılan tahminlerde, MLP ve

ARMA modellerinin yaklaşık aynı sonuçlar verdiğini (Her iki model için yaklaşık nRMSE % 40.5), ARMA-ÇKA -PM Hibrit modelinin ise deneyi gerçekleştirilen modeller arasında nRMSE 36.6% hata oranı ile en iyi sonucu verdiğini gözlemlemişlerdir. Ayrıca ARMA-ÇKA-PM hibrit modelinin oluşturulmasının güç olduğunu vurgulamışlardır.

Yacef vd. (2014), Cezayir Gardaya şehri yüzeyi günlük güneş ışımasını tahmin etmek için birleşik ampirik modeller ve Bayes sinir ağı (BNN) modeli önermişlerdir. Ampirik modellerin katsayılarını ve BNN model eğitimi gerçekleştirilebilmek için 2006 yılına ait günlük maksimum ve minimum hava sıcaklık değerleri kullanılmıştır. 2007 yılı kış ve yaz aylarına ait veriler kullanılarak gerçekleştirilen test sonuçları, önerilen birleşik modellerin tekli modellere oranla daha iyi sonuçlar verdiğini, BNN modelinin genelleme yeteneğinin birleşik ampirik modellere kıyasla daha düşük olduğu gözlenmiştir.

Sun vd. (2015), Çin'de iki farklı bölge yüzeyindeki güneş ışımasını tahminini gerçekleştirebilmek için ARMA ile genelleştirilmiş otoregresif koşullu değişen varyans (GARCH) modelini birleştiren hibrit bir yaklaşım önermişlerdir. Çalışmada ARMA modeli ile 6 farklı GARCH modelinden oluşan farklı hibrit yaklaşımlarını kullanmışlardır. Çalışmalarında 1 Ocak 1983 ile 31 Aralık 2012 tarihleri arasında Çin'in Pekin ve Urumqi şehirlerinde ölçülen toplam günlük güneş ışıması, dünya dışı güneş ışıması, güneş ışığı süresi verilerini kullanmışlardır. Deney sonuçları tahmin hatası açısından ARMA – GOKDV hibrit modelinin, farklı iklim koşullarına sahip her iki bölge için de diğer modellerden daha iyi performans gösterdiğini ortaya koymuştur.

Gairaa vd. (2016), Cezayir'in iki farklı iklim bölgesinde günlük güneş ışıma değerlerini tahmin edebilmek amacıyla ARMA/ANN hibrit modelini önermişlerdir. Önerilen hibrit yöntem, her iki modelin avantajlarını tek bir modelde toplamayı amaçlamıştır. Bu amaç doğrultusunda zaman serisinin doğrusal bileşenleri için ARMA, doğrusal olmayan bileşenleri için ise ANN modeli kullanılmıştır. Bouzareah ve Ghardaia şehirlerinden 2012-2013 yıllarında kaydedilen güneş ışıma verileri ile kullanılarak eğitilmiş ve test edilmiştir. Elde edilen sonuçlar ARMA /ANN hibrit modelinin tekli ARMA ve ANN modellerine oranla ortalama mutlak hata kriteri (MAE) açısından sırasıyla birinci bölge için %18,1 ve %2,7, ikinci bölge için %27,26 ve %1,39 oranında iyileşme gösterdiğini

ortaya koymuştur. Ayrıca tekli ARMA ve ANN modellerine kıyasla RMSE değerlerinde %17,1 ve %3,59 oranlarında azalma gözlenmiştir.

Benmouiza ve Cheknane (2016), uzun süreli, saat ölçekli (915 saat ilerisi) ve daha küçük ölçekli, (30 ve 1 saniye) 1 günlük güneş ışıınımı tahmini gerçekleştirebilmek için ARMA / NAR hibrit model yaklaşımını önermişlerdir. Önerilen yaklaşımda tahmin süreci 3 ana adımda gerçekleşmektedir. İlk adımda 6 dereceli bir polinom modeli ile zaman serisinin trendsizleştirilmesi işlemini (detrending) gerçekleştirmişlerdir. İkinci adımda, zaman serisinin doğrusal bileşeninin tahmini için ARMA modelini, doğrusal olmayan bileşeninin tahmini için ise Doğrusal Olmayan Otoregresif Ağ (NAR) sinir ağını kullanmışlardır. ARMA model çıktısı ve NAR sinir ağı çıktısının toplanması ile nihai güneş ışıınımı tahmini elde edilmiştir. Önerilen hibrit modelin performansını değerlendirmek için dünyanın farklı şehirlerinden farklı yıllarda elde edilen veri setleri (Ghardaia, Londra, Almiria şehirlerinde, sırasıyla 2012, 2005 ve 2010 yıllarında toplanan veriler) kullanılmıştır. Dünyanın farklı iklim koşullarına sahip 3 ayrı bölgesi için gerçekleştirilen deney sonuçları hem saatlik hem de daha küçük ölçekli tahminlerde ARMA / NAR yönteminin başarısını ortaya koymuştur. Ayrıca ARMA / NAR hibrit modelini literatürde çalışmaları yapılmış ARMA/TD-ANN hibrit modeli ile nRMSE hata ölçütü yönünden karşılaştırmışlardır. Sonuçlar ARMA / NAR hibrit modelinin ARMA / TD-ANN hibrit modeline kıyasla daha iyi performans gösterdiğini ortaya koymuştur.

Akarşlan ve Hocaoglu (2016), Türkiye'deki üç farklı bölge için saatlik güneş ışıınımı tahmini gerçekleştirmişlerdir. Güneş ışıınımı tahmininde iki farklı uyarlanabilir yaklaşım kullanmışlardır. İlk yaklaşımda yılın mevsimine göre doğrusal ve ampirik bir tahmin yöntemi kullanılmıştır. İkinci yaklaşımda ise karar verici olarak bulutluluk indeksi kullanılmıştır. Tahminde, bulutluluk indeksi belirli bir değerden düşükse ampirik model, aksi durumda doğrusal model kullanılmaktadır. Deneysel çalışmalar, literatürde yapılmış olan diğer çalışmalara oranla %10 ile %30 arasında değişen daha başarılı sonuçlar elde edilebildiğini göstermiştir.

Wang vd. (2018), Batı Çin'de güneş ışıınımı tahmini gerçekleştirmek amacıyla ayrıştırma-tahmin-yeniden yapılandırma temelli bir yaklaşım önermişlerdir. Bu amaç

doğrultusunda, güneş ışıınımı verilerinin ayrıştırılması için Grupsal Ampirik Kip Ayrışımı (EEMD) ve Dalgacık Analizi (WA), ışıınım verilerinin tahmini için ise ANN ve Regresyon Modeli (RM) kullanmışlardır. Elde edilen deneysel sonuçlar, GAKA-RM'nin günlük tahminlerde yüksek hassasiyet sağladığını, DA-RM'nin ise aylık durumlarda yüksek performans sağladığını göstermiştir.

Prasad vd. (2019), hibrit çok aşamalı tahmin modeli kullanılarak aylık güneş ışıınımı tahmini gerçekleştirmişlerdir. İlk olarak veriler Çok Aşamalı Çok Değişkenli Ampirik Mod Ayrıştırma (MS-MEMD) algoritması kullanılarak bileşenlerine ayrıştırılmıştır. Ardından en iyi bileşenler karınca kolonisi optimizasyonu kullanılarak belirlenmiştir. Elde edilen bileşenlerin gelecek değerleri Rassal Orman (RF) yöntemi kullanılarak tahmin edilmiştir. Son olarak her bir bileşene ait tahmin sonuçlarının birleştirilmesiyle nihai tahmin sonucuna ulaşılmıştır. Deney sonuçları yöntemin güneş ışıınımı tahmininde başarılı bir şekilde kullanılabileceğini ortaya koymuştur.

Rabehi vd. (2020), MLP, Arttırılmış Karar Ağacı (BDT) ve bu modellerin Doğrusal Regresyon modeli ile birleşiminin performanslarını incelemek amacıyla güneş ışıınımı tahminleri gerçekleştirmişlerdir. Her bir model için farklı veri kombinasyonları kullanarak yöntemlerin başarılarını değerlendirmişlerdir. Gerçekleştirilen deneyler sonucunda, MLP modelinin istatistiksel göstergeler açısından diğer modellere kıyasla en iyi sonuçları elde ettiği gözlenmiştir.

Zang vd. (2020), kısa vadeli güneş ışıınımı tahmini için Evrişimli Sinir Ağı (CNN) ve LSTM yöntemlerini birleştirerek hibrit bir yaklaşım öne sürmüşlerdir. İlgili yaklaşım ile birlikte ilk olarak meteorolojik parametrelerden CNN kullanılarak öznitelik çıkarımı gerçekleştirilmiştir. Ardından, geçmiş güneş ışıınımı zaman serisi verilerinden zamansal özellikleri çıkarmak için LSTM yöntemi uygulanmıştır. Son olarak, 1 saat ilerisi için güneş ışıınımı tahminini gerçekleştirebilmek amacıyla iki çıktı birleştirilmiştir. CNN / LSTM modelinin tahmin performansı ve genelleme yeteneği, farklı mevsimler ve gökyüzü koşulları altında Teksas, ABD'deki üç farklı iklim bölgesine yayılmış 34 lokasyondan 1 yıl içinde toplanan veriler kullanılarak değerlendirilmiştir. Sonuçlar,

önerilen modelin dikkate alınan diğer modellere göre avantajlara sahip olduğunu ve kısa vadeli güneş ışıınımı tahmini için iyi bir alternatif sağladığını göstermiştir.

2.5 Tüm Gökyüzü Görüntüleyicilerinin (ASI) Kullanıldığı Çalışmalar

Fu ve Cheng (2013), ASI'dan topladıkları görüntülerden çıkartılan öznitelikleri ve güneş ışıınım zaman serilerini kullanarak bir regresyon modeli oluşturmuşlardır. Oluşturulan bu regresyon modeli ile bulutluluk indeksinin (clearness index) tahminini gerçekleştirmişlerdir. Son olarak, tahmin edilen bulutluluk indeksi ve görüntülerden elde edilen özniteliklerin kullanılmasıyla güneş ışıınım tahminine ulaşmışlardır. Deney sonuçları, tasarlanan bulutluluk indeksi tahmin mekanizmasının doğrudan güneş ışıınımını tahmin etmekten daha iyi tahmin sonuçları verdiğini göstermiştir.

Marquez ve Coimbra (2013), 3 ve 15 dakikalık zaman ufuklarında güneş ışıınımı tahmini gerçekleştirebilmek için ASI'dan elde ettikleri görüntüleri kullanmışlardır. Sıralı görüntüler üzerinde kullanılan görüntü işleme teknikleriyle bulutların tespiti ve hız alanı hesaplamalarını gerçekleştirmişlerdir. Bu sayede kısa zamanlı güneş ışıınımı tahmininde uydu görüntülerini baz alan yöntemlere kıyasla belirgin bir iyileşme göstermişlerdir.

Cheng vd. (2014), 5,10 ve 15 dakikalık zaman ufuklarında güneş ışıınımı tahmini gerçekleştirmişlerdir. Tahmin sürecinde ASI'dan elde edilen farklı öznitelikler ve bulutluluk indeksini kullanmışlardır. Deney sonuçları ASI'dan çıkartılan özniteliklerin tahmin performansını arttırdığını göstermiştir.

Cheng ve Yu (2015), farklı bulut sınıflarının güneş ışıınımı üzerindeki etkilerini incelemişlerdir. ASI sisteminden gelen görüntü ilk olarak sabit ölçülerdeki karelere bölünmüştür. Her bir kare için çıkarılan öznitelikler ve Destek Vektör Sınıflandırıcısı (SVC) kullanılarak ilgili karenin 6 bulut sınıfından hangisine ait olduğu belirlenmiştir. Karelerin bulut sınıf bilgileri belirlendikten sonra oylama sonucunda gökyüzü görüntüsünün sınıfı tespit edilmiştir. Her bir bulut sınıfı için ayrı ayrı oluşturulmuş SVR ve çoklu doğrusal regresyon modelleri kullanılarak 5-10-15 dakikalık zaman ufukları için güneş ışıınımı tahminleri gerçekleştirilmiştir. Deneysel çalışmalar sonucunda güneş

ışınımı düşümünde benzer etkiler gösteren bulut sınıflarının birleştirilmesinin tahmin doğruluğunu arttırdığını, 4 farklı bulut sınıfı kullanılmasının en iyi tahmin sonucunu verdiğini gözlemlemişlerdir. Ayrıca yöntem, literatürde kısa zamanlı güneş ışıınımı tahmini için sunulan diğer yöntemlerle karşılaştırılmıştır ve hata ölçütleri yönünden çok daha iyi performans gösterdiği tespit edilmiştir.

Chu vd. (2015), 2 farklı lokasyondan 6 ay boyunca topladıkları 1'er dakikalık gökyüzü görüntüleri ve güneş ışıınım değerlerini kullanarak 10 dakikalık zaman ufku için 1'er dakikalık çözünürlüklerde rampa olayı ve güneş ışıınımı tahmini gerçekleştirmişlerdir. Elde edilen gökyüzü görüntülerinden bulutluluk indeksi zaman serisi yaratmışlardır. Oluşturulan zaman serisi ve geçmiş güneş ışıınımı değerleri ANN'ye girdi olarak verilmiş, böylelikle güneş ışıınımı ve rampa tahminlerine ulaşılmıştır. ANN katman sayısı, nöron sayısı ve potansiyel girdiler genetik algoritma kullanılarak optimize edilmiştir. Elde edilen sonuçlar ASI'ların kısa vadeli güneş ışıınımı ve rampa tahminlerinde başarılı bir şekilde kullanılabileceğini göstermiştir.

Schmidt vd. (2016), ASI'lardan elde edilen gökyüzü görüntülerinde bulunan bulutların tespit ve takip edilmesi sonucunda hesaplanan bulut hızı ve yön bilgilerini kullanarak bulut hareketi ve güneş ışıınımı tahminleri gerçekleştirmişlerdir. Ayrıca bulut görüntülerinden çıkartılan 16 farklı özniteliğin kullanılmasıyla bulutları 7 farklı sınıfa ayırtmışlardır. Sınıflandırma sonucunda gökyüzünde bulunan baskın bulut bilgisine ulaşmışlardır. Bulut öznitelik noktası belirlemede Shi-Tomasi öznitelik seçme algoritması, tespit edilen öznitelik noktalarının takibinde ise Lucas-Kanade optik akış algoritması kullanmışlardır. Yirmi beş dakikaya kadar zaman ufkunda, 1 saniye çözünürlükte güneş ışıınımı tahminleri gerçekleştirmişlerdir. Gerçekleştirilen çalışma sonucunda yöntem performansının büyük ölçüde baskın bulut koşullarına bağlı olduğu sonucuna varmışlardır.

Chang vd. (2017), bulutları geçirgenliklerine göre 2 farklı sınıfa (az geçirgen, çok geçirgen) ayırmıştır ve takibini gerçekleştirmiştir. Önerdikleri geri projeksiyona dayalı yeni bir tahmin yöntemine bulut geçirgenlik sınıfı ve bulut hareket bilgilerini dahil ederek

güneş ışıını tahmini gerçekleştirmişlerdir. Deney sonuçları önerilen yöntemin makul hata oranlarıyla güneş ışıını tahminini gerçekleştirebildiğini göstermiştir.

Cheng (2017), ASI'lerden elde edilen gökyüzü görüntülerini kullanarak bulut hareketi ve rampa olaylarının tahminini gerçekleştirmişlerdir. Bu amaç doğrultusunda, bulutlara ait köşe ve kenarları harris öznitelik seçme algoritması ile tespit etmiş ve kümelemiştir. Tespit edilen öznitelik noktaları ve kümelerden elde edilen farklı girdilerin destek vektör sınıflandırıcısına verilmesiyle güneş ışıını değeriinde rampa olayı oluşumlarını 5,10,15 ve 20 dakikalık zaman ölçeklerinde tahmin etmişlerdir. Elde edilen deney sonuçları literatürde kullanılan diğer yöntemlere kıyasla daha başarılı sonuçlar elde edilebildiğini ortaya koymuştur.

Scolari vd. (2018), ASI'lerden ve uydulardan elde edilen gökyüzü görüntülerini birlikte kullanarak 1,5 ve 15 dakikalık zaman ölçeklerinde güneş ışıını tahmini gerçekleştirmişlerdir. İlk olarak ASI'dan elde edilen gökyüzü görüntüleri ANN'ye girdi olarak verilmiş ve bulutluluk indeksi tahmin edilmiştir. Ardından aynı işlemler uydu görüntüleri için de uygulanmıştır. Elde edilen tahmin çıktıların birleştirilmesiyle nihai güneş ışıını tahminlerine ulaşılmıştır. Yılın farklı dönemleri için gerçekleştirilen değerlendirmelerde yalnızca görüntü özelliklerine dayalı tahmin yönteminin diğerlerinden daha iyi sonuçlar verdiği, literatürdeki yöntemlere kıyasla %20-45 arasında daha başarılı tahminler yapılabildiği görülmüştür.

Caldas ve Alonso-Suárez (2019), 1-10 dakika aralığında değişen zaman ölçekleri için güneş ışıını tahminleri gerçekleştirilmiştir. ASI'lerden elde edilen gökyüzü görüntüleri üzerinde ilk olarak bulutlar tespit edilmiştir. Ardından geçmiş gökyüzü görüntülerinde bulunan bulutların konumları dikkate alınarak bulut hareket yönleri ve hızlarına ulaşılmıştır. İlgili hız ve yön bilgileri, geçmiş güneş ışıını değerlerinin kullanılmasıyla hesaplanan bulutluluk indeksi bilgilerinin kullanılmasıyla güneş ışıını tahminine ulaşılmıştır. Deney sonuçları, önerilen modelin kısa vadeli güneş ışıını tahmininde başarıyla kullanılabileceğini göstermiştir.

Al-lahham vd. (2020), ASI'dan elde edilen gökyüzü görüntülerini kullanarak 5 saniyelik zaman ölçeklerinde güneş ışıınımı tahmini gerçekleştirmişlerdir. Bulutların ve güneşin gökyüzünden ayrıştırılmasında destek vektör sınıflandırıcı kullanmışlardır. Bulut sınıflandırması sonrasında görüntülerden çıkartılan 17 farklı özneteliğin ANN'ye verilmesiyle güneş ışıınımı tahminlerini gerçekleştirmişlerdir. Yöntem güneş ışıınımında bulunan yüksek dalgalanmalara rağmen oldukça başarılı sonuçlar elde etmiştir.

Doodkorte (2021), kısa vadeli güneş ışıınımı tahmini için ASI kullanılarak elde edilen sıralı gökyüzü görüntülerini ve meteorolojik verileri kullanmışlardır. Oluşturulan derin öğrenme modeli ile 0-21 dakika aralığındaki zaman ufukları için güneş ışıınımı tahminleri gerçekleştirmişlerdir. Farklı gökyüzü koşulları için yöntemin başarısını literatürde yer alan diğer geleneksel yöntemlerle karşılaştırmışlardır. Derin öğrenme modelinin geleneksel yöntemlere kıyasla %24,8 ile daha iyi performans gösterdiğini ortaya koymuşlardır.

3. MATERYAL ve METOT

Bu bölümde kurulan deney düzeneği, veri toplama süreci ve geliştirilen yaklaşımda kullanılan yöntemler aktarılmıştır. Bu kapsamda bölüm 3.1’de kurulan deney düzeneği ve verilerin toplanması, 3.2’de öznelik noktalarının bulunması ve takip sürecine ait yöntemler, 3.3’de bulut, gökyüzü ve güneş tespit yöntemleri, 3.4’de bulut hareketi tahmin yöntemi ve son olarak 3.5’de güneş ışıınımı tahmin yöntemi verilmiştir.

3.1 Kurulan Deney Düzeneği

Kısa vadeli güneş ışıınımı tahmininde bulut örtüsü önemli bir yere sahiptir. Gün içerisinde gökyüzünde bulunan bulutların tespit edilebilmesi, hız ve hareket yönlerinin belirlenebilmesi, dolayısıyla detaylı bulut bilgisinin tahmin sürecine dahil edilebilmesi için gökyüzü görüntülerine ihtiyaç duyulmaktadır. Ayrıca, ilgili bulutluluk durumlarındaki güneş ışıınımı değişimlerinin model tarafından öğrenilebilmesi ve tahminlerin gerçekleştirilebilmesi için güneş ışıınımı verileri gerekmektedir. Bu kapsamda, gerçekleştirilen tez çalışmasında ihtiyaç duyulan verilerin elde edilebilmesi için Afyon Kocatepe Üniversitesi, Güneş ve Rüzgâr Enerjisi Uygulama ve Araştırma Merkezi’nde (GÜRAM) bir deney düzeneği oluşturulmuştur.

Deney düzeneğinde, belirli aralıklarla gökyüzü görüntülerini toplamak ve güneş ışıınımı değerlerini elde edebilmek için birer adet dijital fotoğraf makinesi ve piranometre bulunmaktadır. Piranometre olarak GÜRAM’da güneş ışıınımı ölçümleri için halihazırda kullanılmakta olan Kipp&Zonen marka piranometreden yararlanılmıştır. Canon EOS 80D Dijital fotoğraf makinesi ise proje kapsamında temin edilmiştir. Resim 3.1’de GÜRAM çatısına yerleştirilmiş olan dijital fotoğraf makinesi, Resim 3.2’de ise kullanılan piranometre görülebilmektedir.



Resim 3.1 Afyon Kocatepe Üniversitesi Güneş ve Rüzgâr Uygulama ve Araştırma Merkezi çatısına yerleştirilmiş dijital fotoğraf makinesi.



Resim 3.2 Afyon Kocatepe Üniversitesi Güneş ve Rüzgâr Uygulama ve Araştırma Merkezinde bulunan piranometre.

3.1.1 Güneş Işınımının Ölçülmesi

Küresel güneş ışıınımı değeri, farklı ölçüm yöntemleri bulunmakla birlikte, genellikle piranometre kullanılarak ölçülmektedir. Piranometreler, üzerine farklı yönlerden gelebilecek güneş enerjisini ölçebilecek şekilde tasarlanmıştır. Bu ölçü aletinin

dedektörleri, güneş enerji spektrumunun üzerinde radyasyonun dalga boyundan bağımsız bir tepkiye sahip olmalıdır. Bununla birlikte, güneş radyasyonunun geliş açısından bağımsız bir tepkiye sahip olmaları da gerekmektedir. Birçok piranometrenin dedektörleri, rüzgâr, yağmur gibi dış etkenlerden korunabilmesi için iki yarım küre şeklinde ince cam ile kaplanmıştır. Bu cam kaplamalar, üzerine gelen radyasyonu eşit ve dengeli dağıtabilmek için tekdüze ve ince olmaktadır (Akarslan 2014).

Günümüzde kullanımı en yaygın olan piranometre tasarımlarında, iletken kayıplarına karşı yalıtılmış, konvektif kayıp korumalı ince kararmış bir emici yüzeye bağlı ısıl pil (thermopile) bulunmaktadır. Isıl piller ise, birbirine seri bağlanmış birden fazla ısılçift'ten (thermocouples) oluşmaktadır. Piranometreler, bu ısıl pil algılayıcısı ile birlikte üzerine düşen ışıınım şiddetine bağlı olarak voltaj çıkışı üretmektedir. İlgili voltaj çıkışını algılamak ve kaydetmek için bir potansiyometre kullanılmaktadır. Son olarak, ışıınıma bağlı olarak üretilen voltaj çıkışı belirli kalibrasyonlar gerçekleştirilerek güneş ışıınımı değerine dönüştürülmektedir (Vecan 2011).

Bu tez çalışmasında, gerçekleştirilen güneş ışıınımı tahminlerinde Afyonkarahisar'a ait güneş ışıınımı verileri kullanılmıştır. Güneş ışıınımı verilerinin ölçümü, GÜRAM'da var olan ve deney düzeneği kapsamında yararlanılan, Kipp&Zonen marka CMP-6 model birinci sınıf bir piranometre kullanılarak gerçekleştirilmiştir (Resim 3.2). Bu ölçüm cihazı, 5-20 μWm^2 ölçme hassasiyetine sahip ve 64 ısılçift bileşenlerini algılayabilen, ısıl pil tipi bir piranometredir. Piranometreye ait detaylı teknik özellikler Çizelge 3.1'de verilmiştir (Kaynak: Kipp&Zonen)


Çizelge 3.1 Kipp&Zonen CMP6 piranometre teknik özellikleri (İnt. Kyn. 2).

Özellik	Açıklama
ISO Sınıfı	Birinci Sınıf
Tepki Süresi (Final Değerinin %95'i)	< 18 s
Hassasiyet	5-20 $\mu\text{W}/\text{m}^2$
Spektral Aralık	285 - 2800 nm
Hassasiyet'in Sıcaklığa Bağlılığı	< 4 % (-10°C - +40°C)
Sıfır ofset - Termal radyasyon (200 W / m^2)	< 12 W/ m^2
İstikrarsızlık (değişim / yıl)	< %1

Çizelge 3.1 (Devam) Kipp&Zonen CMP6 piranometre teknik özellikleri (İnt. Kyn. 2).

Yön hatası (1000 W/m ² ile 80 ° 'ye kadar)	< 20 W/m ²
Empedans	20-200 Ω
Çalışma Sıcaklığı	(-40°- +80°C)
Seviye hassasiyeti	1°
Duyarlılık	5-20 µV/W/m ²
Maksimum Işınım	2000 W/m ²

Yukarıda teknik detayları verilmiş olan Kipp&Zonen CMP-6 model piranometre kullanılarak 1 Eylül 2021 – 1 Ekim 2021 tarihleri arasında güneş ışıınımı verileri toplanmıştır. Işınım verileri her gün 10.00-16.00 saatleri arasında 10'ar saniyelik aralıklarla ölçülmüş ve kaydedilmiştir. Şekil 3.1'de 3 Eylül 2021 tarihinde 10'ar saniyelik zaman ölçeğinde toplanan 1 günlük güneş ışıınımı verileri görülebilmektedir.



Şekil 3.1 3 Eylül 2021 tarihinde, kurulan deney düzeneği yardımıyla toplanan 10'ar saniyelik güneş ışıınımı zaman serisi.

3.1.2 Gökyüzü Görüntülerinin Toplanması

Gerçekleştirilen tez çalışmasında, gün içerisinde gökyüzünde bulunan bulutlara ait konum, hareket ve hız bilgilerinin detaylıca analiz edilmesi, elde edilen bilgilerin ise tahmin sürecine katılması amaçlanmıştır. Böylelikle, güneş ışıınımı değişkenliklerine

sebebi olan en temel etmenlerden biri olan bulut örtüsü dikkate alınarak güneş ışınımı tahminleri gerçekleştirilmesi hedeflenmiştir. Bu amaç doğrultusunda, gün içerisinde gökyüzünde bulunan bulutların tespit edilmesi, konum, hız ve hareket yönlerinin belirlenmesi gerekmektedir. İlgili tüm işlemler, görüntü işleme yöntemlerine dayanan teknikler kullanılarak gerçekleştirildiği için gökyüzü görüntüleri girdisi oldukça kritik bir öneme sahiptir.

Çalışmada, gökyüzü görüntülerinin toplanmasında GÜRAM’da kurulan deney düzeneğine yerleştirilen Canon EOS 80D dijital fotoğraf makinesi kullanılmıştır. Dijital fotoğraf makinesine takılan 8mm F3.5 balık gözü mercek ile birlikte 167°’lik bir görüş açısına ulaşılmıştır. Görüntüler, 1 Eylül 2021 – 1 Ekim 2021 tarihleri ve 10:00-16:00 saatleri arasında her 10 saniyede bir fotoğraf çekilerek toplanmıştır. Çekimler 1/2500s poz süresi, ISO100, RGB, 4000x6000 piksel çözünürlüğü ayarları kullanılarak gerçekleştirilmiştir ve görüntüler JPEG formatında saklanmıştır. Görüntülerin elde edilmesinde kullanılan Canon EOS 80D dijital fotoğraf makinesine ait detaylı teknik özellikler Çizelge 3.2’de, kullanılan balık gözü merceğe ait teknik özellikler ise Çizelge 3.3’de verilmiştir.

Çizelge 3.2 Canon EOS 80D dijital fotoğraf makinesi teknik özellikleri (İnt. Kyn. 3).

Özellik	Açıklama
Kamera Biçimi	APS-C
Piksel	25,8 Megapiksel
Maksimum Çözünürlük	6000 x 4000
En Boy Oranı	1: 1, 3: 2, 4: 3, 16: 9
Sensör Tipi	CMOS
Görüntü Dosyası Biçimi	JPEG, Raw
Bit Derinliği	14-Bit
ISO Hassasiyeti	Otomatik, 100-16000
Pozlama Telafisi	-5 / +5 EV
Ölçüm Aralığı	1 / 20 EV
Çalışma sıcaklığı	-5 / 45 ° C
Pil	Lityum İyon, 7,2 VDC
Boyutlar (G x Y x D)	139 x 105,2 x 78,5 mm
Ağırlık	730 g

Çizelge 3.3 Samyang F3.5 /8mm balık gözü mercek teknik özellikleri (İnt. Kyn. 4).

Özellik	Açıklama
Odak Uzaklığı	8 mm
Diyafram	Maksimum: f / 3.5 – Minimum f / 22
Sensör Biçimi	Canon Crop DSLR
Bakış Açısı	167°
Minimum Odak Mesafesi	12 "(30.48 cm)
Boyutlar	75 x 77.3 mm
Ağırlık	428 g

3.2 Bulut Hareketi Takibi

Belirli aralıklarda toplanan gökyüzü görüntülerinden, bulutların hareket yönleri ve hızlarının tespit edilebilmesi için ilk olarak bulutların gerçekleştirdikleri hareketlerin takip edilmesi gerekmektedir. Bu amaç doğrultusunda ilk olarak bulutlar üzerinde takip edilmeye en uygun öznitelik noktaları belirlenmeli, ardından da belirlenen öznitelik noktaları sıralı gökyüzü görüntüleri boyunca takip edilmelidir. Tez çalışması kapsamında gerçekleştirilen bulut hareketi takibi iki aşamada gerçekleştirilmiştir. İlgili aşamalarda gerçekleştirilenler 3.2.1 takip edilecek öznitelik noktaların bulunması ve 3.2.2 öznitelik noktalarının takibi bölümlerinde açıklanmıştır.

3.2.1 Takip Edilecek Öznitelik Noktalarının Bulunması

Belirli aralıklarla çekilen gökyüzü görüntüleri üzerinde bulutların gerçekleştirdiği hareketlerin yakalanabilmesi için, ilk olarak bulutlar üzerinde takip edilmeye en uygun öznitelik noktaların belirlenmesi gerekmektedir. Bu öznitelik noktaları, görüntü geçişlerinde takibi nispeten daha kolay olan, yüksek renk geçişleri veya yoğunluğa sahip pikseller olmakla birlikte genellikle nesnelerin köşelerinde veya kenarlarında bulunmaktadır. Öznitelik noktalarının belirlenmesinde günümüze kadar literatürde farklı birçok yöntem kullanılmıştır. Kenney vd. (2005), gerçekleştirdikleri çalışmada, literatürde yaygın olarak kullanılan öznitelik seçme algoritmalarının performanslarını karşılaştırmışlardır. Bu kapsamda, Harris-Stephens, Forstner, Shi-Tomasi, Rohr ve p-norm durum dedektörü gibi algoritmaları dört farklı aksiyoma göre değerlendirmişlerdir.

Shi-Tomasi algoritması ilgili çalışmada tüm aksiyomları karşılayan tek algoritma olarak ön plana çıkmıştır. Bu tez çalışmasında, öznelite noktalarının belirlenmesinde literatürdeki yaygın kullanımı ve performans değerlendirmeleri göz önünde bulundurularak Shi-Tomasi algoritması tercih edilmiştir.

Shi-Tomasi algoritması, Harris ve Stephens'in geliştirmiş olduğu algoritmada ufak bir değişiklik gerçekleştirilmesi sonucu ortaya çıkmıştır. Harris ve Stephens'in geliştirdiği algoritmada ilk olarak piksel etrafında bir pencere oluşturulmaktadır. Bu pencerenin farklı yönlerde ufak miktarlarda kaydırılması sonucunda görüntüde oluşan yoğunluk değişimleri hesaplanmaktadır. Elde edilen yoğunluk değişimi değerlerine göre ilgili pikselin kenar, köşe veya düz bir yüzey olduğuna karar verilmektedir. (x,y) koordinatlarında, $I_{(x,y)}$ yoğunluğunda olan bir pikselin, (u,v) kadar kaydırıldığında oluşacak yoğunluk değişimi $E_{(u,v)}$ denklem (3.1)'de verilmiştir (Mstafa vd. 2020).

$$E_{(u,v)} = \sum_{x,y} w(x,y) [I_{(x+u,y+v)} - I_{(x,y)}]^2 \quad (3.1)$$

Bu denklemde;

- E = Orijinal ve kaydırılan pencere arasındaki kareler farkının toplamı,
- u = Pencerenin x koordinatındaki yer değiştirmesi,
- v = Pencerenin y koordinatındaki yer değiştirmesi,
- $w(x,y)$ = (x,y) koordinatındaki pencerenin ağırlıklandırma fonksiyonu,
- $I_{(x+u,y+v)}$ = Kaydırılan pencerenin yoğunluğu,
- $I_{(x,y)}$ = Orijinal pencerenin yoğunluğunu

ifade etmektedir. Taylor serisi kullanılarak denklem (3.1) daha da genişletilerek tekrar yazılırsa denklem (3.2) elde edilecektir.

$$E_{(u,v)} \approx \sum_{x,y} w(x,y) [I_{(x,y)} + uI_x + vI_y - I_{(x,y)}]^2 \quad (3.2)$$

Denklem (3.2)'nin matris formatında tekrar yazılmasıyla denklem (3.3) elde edilebilmektedir.

$$E_{(u,v)} \approx [u \ v] \left(\sum_{x,y} w(x,y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \right) \begin{bmatrix} u \\ v \end{bmatrix} \quad (3.3)$$

Denklem (3.3)'ün sadeleştirilmesiyle denklem (3.4)'e ulaşılmaktadır.

$$E_{(u,v)} \approx [u \ v] A \begin{bmatrix} u \\ v \end{bmatrix} \quad (3.4)$$

Denklem (3.4)'de verilen A Harris Matrisini (Otokorelasyon Matrisi) temsil etmektedir ve denklem (3.5)'deki gibi tanımlanmaktadır.

$$A = \sum_{x,y} w(x,y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \quad (3.5)$$

Harris ve Stephens, öz değerleri λ_1 ve λ_2 şeklinde gösterilen otokorelasyon matrisinin determinantından belirlenen bir katsayı ile çarpılmış matrisin izini (trace) çıkartan bir fonksiyon önermiştir. Fonksiyon çıktısını ise önceden belirlenmiş olan bir eşik değeriyle karşılaştırmıştır. Önerilen fonksiyon denklem (3.6)'da verilmiştir.

$$R = Det(A) - K(Trace(A))^2 = \lambda_1 \times \lambda_2 - K(\lambda_1 + \lambda_2)^2 \quad (3.6)$$

Bu denklemde;

$$Det(A) = \lambda_1 \times \lambda_2,$$

$$Trace(A) = \lambda_1 + \lambda_2,$$

$$\lambda_1 \text{ ve } \lambda_2 = \text{Otokorelasyon Matrisi (A)'nın özdeğerleri},$$

$$K = \text{Sabit Katsayı}$$

ifade etmektedir. Denklem (3.6)'nın kullanılmasıyla hesaplanan R değerine göre bir nokta şu şekillerde kabul edilir (Mstafa vd. 2020);

- **Köşe:** Eğer her iki özdeğer de büyük ve yakın değerliyse ($\lambda_1 \approx \lambda_2$),
- **Kenar:** Her iki özdeğerden birisi diğerinden büyükse ($\lambda_1 > \lambda_2$) veya ($\lambda_2 > \lambda_1$),
- **Düz:** Her iki özdeğer de küçükse (λ_1, λ_2),.

Shi-Tomasi algoritmasında da R değerine göre ilgili noktanın kenar veya düz olduğuna karar verilmektedir. Ancak Shi-Tomasi algoritmasında R değeri farklı şekilde hesaplanmaktadır. Shi-Tomasi algoritmasında R değerinin hesaplanmasında kullanılan formül denklem (3.7)'de verilmiştir.

$$R = \min(\lambda_1, \lambda_2) \quad (3.7)$$

Hesaplanan R değeri önceden belirlenmiş olan bir eşik değerinden büyükse, değerlendirilen nokta kenar olarak kabul edilmektedir. Shi-Tomasi algoritması, takip uygulamaları için daha kararlı ve doğru öznitelik noktaları üretmektedir. Ancak, Harris ve Stephens yöntemine oranla daha fazla işlem yükü bulunmaktadır (Příbyl vd. 2012).

Gökyüzü görüntülerinde bulutlara ait kenar ve köşe noktaların doğru tespit edilmesi büyük öneme sahiptir. Bu sayede bulutların hareketlerinin takibi sağlanmakta, ayrıca hesaplanan hız ve yön bilgileri kullanılarak güneşin önünü kapatma süreleri tahmin edilebilmektedir. Çalışmada ilgili bu noktaları ön plana çıkartabilmek ve Shi-Tomasi yönteminin performansını arttırabilmek amacıyla görüntünün mavi ve kırmızı renk kanalları arasındaki fark görüntüsü kullanılmıştır. Yöntemin uygulanması aşamasında Python OpenCV kütüphanesinde bulunan `goodFeaturesToTrack()` fonksiyonu kullanılmıştır. Bu sayede görüntü üzerinde bulunan takip için en uygun öznitelik noktaları bulunmuş ve konum bilgilerine ulaşılmıştır.

3.2.2 Öznitelik Noktalarının Takibi

Shi-Tomasi algoritması kullanılarak öznitelik noktalarının elde edilmesinin ardından belirlenen noktaların sıralı gökyüzü görüntüleri boyunca takip edilmesi gerekmektedir. Böylelikle takip noktalarının sıralı görüntüler boyunca gerçekleştirdiği harekete ait yön

ve hız bilgilerine ulaşılabilmektedir. Bu tez çalışmasında öznitelik noktalarının takip edilmesinde optik akış yönteminden yararlanılmıştır.

Optik akış, bir görüntüde bulunan nesnelerin hareketinin veya görüntü hızının gözlemciye göre ölçülmesidir (Lucas ve Kanade 1981). Optik akış yönteminde, her bir pikselin kareler (frame) arasındaki değişimi dikkate alınarak hareketin hızı ve yönü bulunmaktadır. Yöntem, akışın başta sabit olduğunu varsayarak ilk olarak yerel komşuları değerlendirmektedir. Ardından temel optik akış denklemlerinin kullanılmasıyla algoritma tüm pikseller için çalıştırılmaktadır (Barron vd. 1994). İki görüntü arasındaki optik akış denklem (3.8)'de verilmiştir (Zhang vd. 2014). Bu denklemde piksel yoğunluğu, (x, y) konumunun t anındaki bir fonksiyonu olarak ifade edilmektedir.

$$f(x, y, t) = f(x + \Delta x, y + \Delta y, t + \Delta t) \quad (3.8)$$

Sıralı kareler arasında piksel yer değiştirmesinin küçük olduğu varsayılarak, denklemin sağ tarafı birinci dereceden Taylor açılımı ile yaklaşık olarak hesaplanabilir. Böylelikle denklem (3.9) ve (3.10)'a ulaşılır.

$$f(x, y, t) = f(x, y, t) + \frac{\partial f}{\partial x} \Delta x + \frac{\partial f}{\partial y} \Delta y + \frac{\partial f}{\partial t} \Delta t \quad (3.9)$$

$$\frac{\partial f}{\partial x} v_x + \frac{\partial f}{\partial y} v_y = -\frac{\partial f}{\partial t} \quad (3.10)$$

Literatürde, günümüze kadar optik akışın hesaplanmasında farklı birçok yöntem kullanılmıştır. Barron vd. (1994) gerçekleştirdikleri çalışmada optik akış hesaplamasında kullanılan yöntemleri incelemiş ve performanslarını karşılaştırmıştır. Sonuç olarak, farklı veri setleri üzerinde gerçekleştirilen deneylerde en güvenilir sonuçları veren yöntemlerden birinin Lucas-Kanade optik akış yöntemi olduğu sonucuna ulaşılmıştır. Gerçekleştirilen tez çalışmasında optik akışın hesaplanmasında, Barron ve arkadaşlarının elde ettiği bulguların yanında, bulutların yavaş hareketleri ve literatürdeki yaygın kullanımı göz önünde bulundurularak Lucas-Kanade optik akış yöntemi kullanılmıştır. Lucas-Kanade yöntemi, kareler arasında öznitelik noktalarının yer değişiminin küçük

olduğunu ve öznitelik noktalarında ve çevresinde bulunan piksellerde yerel akış olduğunu varsaymaktadır (Lucas ve Kanade 1981). Bu varsayım sayesinde, denklem (3.10)'da bulunan iki bilinmeyenli denklem, piksel etrafında bir pencere oluşturularak çözülebilir duruma gelmektedir. Pencerede q bir piksel, $q_1, q_2, \dots, q_n$ ise n adet komşu piksel olmak üzere oluşan lineer denklem sistemi denklem (3.11)'de verilmiştir.

$$\begin{aligned} \frac{\partial f}{\partial x}(q_1)v_x + \frac{\partial f}{\partial y}(q_1)v_y &= -\frac{\partial f}{\partial t}(q_1) \\ &\vdots \\ \frac{\partial f}{\partial x}(q_n)v_x + \frac{\partial f}{\partial y}(q_n)v_y &= -\frac{\partial f}{\partial t}(q_n) \end{aligned} \quad (3.11)$$

Sonuç olarak, her bir piksele ait v_x ve v_y hız değerinin denklem (3.14) ile hesaplanabildiği, potansiyel olarak en küçük kareler yöntemiyle çözülebilen bir sisteme ulaşılmış olur (Zhang vd. 2014).

$$A = \begin{bmatrix} \frac{\partial f}{\partial x}(q_1) & \frac{\partial f}{\partial y}(q_1) \\ \vdots & \vdots \\ \frac{\partial f}{\partial x}(q_n) & \frac{\partial f}{\partial y}(q_n) \end{bmatrix} \quad (3.12)$$

$$b = \begin{pmatrix} -\frac{\partial f}{\partial t}(q_1) \\ \vdots \\ -\frac{\partial f}{\partial t}(q_n) \end{pmatrix} \quad (3.13)$$

$$(v_x, v_y)^T = (A^T A)^{-1} A^T b \quad (3.14)$$

Lucas-Kanade optik akış yönteminin uygulanması aşamasında Python OpenCV kütüphanesi içerisinde yer alan `calcOpticalFlowPyrLK()` fonksiyonundan yararlanılmıştır. Fonksiyon, takip edilmek istenen öznitelik noktalarına ait koordinat bilgilerini ve sıralı iki görüntüyü giriş olarak almaktadır. Geçmiş kare üzerinde belirtilen öznitelik noktalarını bir sonraki kare üzerinde tespit ederek yeni koordinat bilgilerini geriye döndürmektedir. Sıralı gökyüzü görüntüleri üzerinde kaç kare boyunca öznitelik

noktası takibi gerçekleştirileceği kullanıcı tarafından belirlenmektedir. Bu tez çalışmasında öznitelik noktalarının takibi sıralı 6 kare boyunca gerçekleştirilmiş ve her bir aşamadaki koordinat bilgileri kaydedilmiştir. Kaydedilen koordinat bilgilerinin kullanılmasıyla, her bir öznitelik noktasının takip süresi boyunca gerçekleştirdiği hareketlere ait hız ve yön bilgilerine ulaşılmıştır.

3.3 Güneş ve Bulut Tespiti

Bulut hareketi tahminlerinin gerçekleştirilebilmesi için çekilen gökyüzü görüntüleri üzerinde bulunan güneş, gökyüzü ve bulutların tespit edilmesi gerekmektedir. Bu aşamada görüntüde bulunan her bir pikselin güneş, gökyüzü ve bulut olmak üzere 3 farklı sınıfa ait olma durumu söz konusudur. Dolayısıyla, çalışma kapsamında gökyüzü görüntülerinde bulunan her bir piksel ayrı ayrı ele alınmış ve sınıflandırmaları farklı yöntemler kullanılarak gerçekleştirilmiştir. İlgili tüm piksellerin sınıflarının belirlenmesinin ardından gökyüzü görüntüsü üzerinde bulunan güneş, bulut ve gökyüzü tespitleri gerçekleştirilmiş olmaktadır.

Bu tez çalışmasında bulut tespiti için farklı şartlar altındaki başarıları göz önünde bulundurularak “kırmızı/mavi oranı” ve “K-means kümeleme” yöntemlerinin birleşiminden oluşan hibrit bir yaklaşım kullanılmıştır. Bu sayede her iki yöntemin de üstün olduğu durumlarda kullanılması sağlanmış, böylelikle daha başarılı bulut tespiti sonuçlarına ulaşılmıştır. Ayrıca, görüntüde bulunan güneşin tespit edilmesinde gökyüzü indisi (SI) ve parlaklık indisi (BI) parametrelerinden yararlanılmıştır. Hibrit yaklaşımda ve güneş tespitinde kullanılan yöntemlere ait detaylı bilgiler ilgili alt başlıklarda aktarılmıştır.

3.3.1 Kırmızı/Mavi Oranı ile Bulut Tespiti

Havada bulunan moleküllerin, mavi ışığı kırmızı ışıktan daha fazla saçmasına karşın, bulutların mavi ve kırmızı ışığı benzer oranlarda saçmaları nedeniyle literatürde birçok çalışma, bulutların gökyüzünden ayrıştırılmasında kırmızı/mavi oranına dayalı bir yaklaşım kullanmıştır (Heinle vd. 2010). Çalışmamızda da literatürdeki yaygın kullanımı

ve başarılı sonuçları dikkate alınarak kırmızı/mavi oranına dayalı standart yaklaşım tercih edilmiştir.

İlgili yaklaşımda ilk olarak görüntü üzerinde bulunan her bir piksele ait kırmızı/mavi oranı hesaplanmaktadır. Ardından hesaplanan değer, belirli bir eşik değeri ile karşılaştırılmaktadır. Hesaplanan değer, eşik değerinden yüksek olması durumunda ilgili piksel bulut, aksi takdirde gökyüzü olarak sınıflandırılmaktadır. Eşik değeri, analizi gerçekleştirilen gökyüzü durumuna göre kullanıcı tarafından belirlenmektedir. Eşik değerinin yüksek seçilmesi durumunda bulut olan pikseller gökyüzü, düşük seçilmesi durumunda ise gökyüzü olan pikseller bulut olarak yanlış sınıflandırılabilmektedir. Bu nedenle eşik değerinin seçimi, bulut/gökyüzü sınıflandırmasının doğru bir şekilde gerçekleştirilebilmesi açısından büyük öneme sahiptir.

Her bir pikselin eşik değeri ile karşılaştırılmasından sonra bulut veya gökyüzü olarak sınıflandırılmasının ardından, görüntü boyutlarına eşit şekilde oluşturulan bulut tespit görüntü üzerinde bulut olan pikseller kırmızı, gökyüzü olan pikseller ise mavi renk ile gösterilmektedir.

3.3.2 K-means Kümeleme Yöntemi ile Bulut Tespiti

K-means kümeleme yöntemi veri öğelerini kullanıcı tarafından belirlenen “k” sayıda gruba bölen popüler bir yöntemdir. Yöntemin temel amacı denklem (3.15)’de verilen kareler toplamı hatasını minimize etmektir.

$$E = \sum_{q=1}^K \sum_{p=1}^N \|x_p^{(q)} - c_q\|^2 \quad (3.15)$$

Denklemden, E kareler toplamı hatasını, $x_p^{(q)}$ herhangi bir veri noktasını, c_q ise küme merkezini belirtmektedir. Kareler toplamı hatasını minimize etmek için 4 adımdan oluşan bir algoritma takip edilmektedir.

1. Kullanıcı tarafından belirlenen “k” sınıf sayısı kadar rastgele merkez noktaları belirlenir.
2. Her bir veri noktasının merkez noktalarına olan uzaklıkları hesaplanır ve kendilerine en yakın olan merkez noktasına ait sınıfa atanır.
3. Her bir veri noktasının atama işlemi tamamlandıktan sonra farklı sınıf etiketlerine sahip verilerin ortalaması bulunarak merkez noktalar tekrar hesaplanır.
4. 2 ve 3. aşama yakınsama kriteri sağlanana kadar (merkez noktaları hareket etmeyene kadar) tekrarlanır. Yakınsama kriteri sağlandığında algoritma sonlandırılır.

Çalışmamızda K-means yöntemi bulutların gökyüzünden ayrıştırılması amacıyla kullanılmıştır. Bu amaç için gökyüzü görüntüsü RGB (kırmızı, yeşil, mavi) uzayından, bulutların gökyüzünden daha yüksek doğrulukla ayrılabilceği LAB (değer, tonlama, doygunluk) uzayına dönüştürülmüştür. Ardından her bir piksele ait a ve b değerleri K-means yöntemine girdi olarak verilerek gökyüzü ve bulut tespitleri gerçekleştirilmiştir. Ayrıca güneş yakınında bulunan bulutların tespit edilmesinde ve yanlış tespitlerin önlenmesinde yine K-means yönteminden yararlanılmıştır.

3.3.3 Güneş Tespiti

Tüm gökyüzü görüntüleyicilerinden elde edilen görüntülerde güneşin ve yakınındaki bulutların tespit edilmesi oldukça zorlu bir işlemdir. Güneşin sahip olduğu yüksek parlaklık nedeniyle güneş önünü kapatan veya yakınında bulunan ince bulutlar güneş ile eşdeğer oranda parlak gözükebilmekte ve yanlış sınıflandırmalara yol açabilmektedir. Buna ek olarak, güneşin açıkta bulunduğu durumlarda güneş etrafında bulunan parlak alan bulut tespit yöntemleri tarafından bulut olarak değerlendirilmektedir. Güneşin oluşturduğu bu bozucu etkinin ortadan kaldırılması ve doğru bir şekilde görüntü üzerinde sınıflandırmaların gerçekleştirilebilmesi için literatürde güneş takip sistemlerine entegre biçimde çalışan tüm gökyüzü görüntüleyicilerinin kullanımı oldukça yaygındır. Bu sistemlerde tüm gökyüzü görüntüleyicisi merkezinde bir engel bulunmakta ve ilgili engelin güneşi fiziksel olarak kapatmasıyla güneşin bozucu etkileri ortadan kaldırılabilir. Çalışmamızda kullanılan tüm gökyüzü görüntüleyici sisteminin

güneş takip sistemini barındırmaması nedeniyle güneşin bozucu etkilerinin çeşitli görüntü işleme yöntemleriyle önüne geçilmeye çalışılmıştır. Böylelikle güneş takip sistemi gibi maliyetli bir çözüme alternatif farklı çözümler geliştirilmiştir.

Gökyüzü görüntülerinde güneşin tespit edilebilmesi amacıyla günümüze kadar literatürde farklı birçok yöntem kullanılmıştır. Akseker (2016) güneşin görüntüdeki yerini tespit etmeye yönelik literatürde kullanılan farklı birçok yöntemi incelemiş ve Yamashita vd. (2004) tarafından kullanılan yöntemin en başarılı sonuçları verdiğini gözlemlemiştir. Gerçekleştirilen çalışmada da ilgili yöntem kullanılarak güneşin görüntüdeki yeri belirlenmiştir. Bu yöntemde gökyüzü indisi (SI) ve parlaklık indisi (BI) adı verilen indisler tanımlanmış ve ilgili indisler güneşin konumunu belirleme amacıyla kullanılmıştır. SI indisi (mavi renk kanalı-kırmızı renk kanalı)/(mavi renk kanalı + kırmızı renk kanalı) ve BI indisi (mavi renk kanalı + kırmızı renk kanalı + yeşil renk kanalı)/3 olarak tanımlanmıştır. İlgili indislerin piksel bazında belirli eşik değerleriyle karşılaştırılması sonucunda güneşin görüntüdeki konumuna ulaşılmıştır.

İlgili yönteme ek olarak, güneşin bulutlar tarafından kapalı olduğu veya güneş önünde parçalı bulutların bulunması durumlarında güneşin konumu kullanıcı tarafından girilmiş ve bu konumda oluşturulan bir maske yardımıyla güneşin sınıflandırılması gerçekleştirilmiştir. Güneşin açıkta olup olmadığının, dolayısıyla hangi güneş tespit yönteminin kullanılacağına ise Hough daire algılama yöntemiyle karar verilmiştir (Yuen vd. 1990). SI ve BI değerleri kullanılarak bulunan güneş piksellerinin oluşturduğu şekil Hough daire algılama yöntemiyle incelenmiş ve şeklin daire olması durumunda güneşin açıkta olduğuna karar verilmiştir. SI ve BI değerleri kullanılarak güneş pikseli bulunamaması veya bulunan piksellerin düzgün daire şeklinde bulunmaması durumunda ise güneşin önü kapalı olarak değerlendirilmiştir. Hough daire algılama yönteminin kullanılmasında OpenCV kütüphanesinde bulunan cv2.HoughCircles() fonksiyonundan yararlanılmıştır.

3.4 Bulut Hareketi Tahmini

Gelecekte gerçekleşecek olan bulut hareketlerini tahmin edebilmek için bulutların geçmişte yaptığı hareketlerden yön ve hız bilgilerinin hesaplanması gerekmektedir. Bu amaç doğrultusunda ilk olarak öznitelik noktalarının geçmiş her karede bulunduğu konumları kesen bir regresyon doğrusu hesaplanmıştır. Ardından her bir öznitelik noktasının çizilen regresyon doğrusu üzerinde ilk konumundan son konumuna kadar kat ettiği mesafe bulunmuştur. Bulunan mesafenin, görüntü takibi gerçekleştirilen kare sayısına bölünmesiyle ilgili öznitelik noktalarının bir karedeki hızlarına ulaşılmıştır. Elde edilen hızlar saniye/piksel birimine sahiptir. Tüm öznitelik noktalarının hız ve yönlerinin bulunmasının ardından ortalama bulut hızı ve yönleri hesaplanmıştır. Ardından, sınıflandırma gerçekleştirilen bulut tespit görüntüsü üzerinde bulut olarak sınıflandırılmış tüm piksellerin hesaplanan ortalama hız ve yön kadar kaydırılmasıyla 1 kare sonrası için bulut hareketi tahminine ulaşılmıştır. Kaydırma işleminin gerçekleştirilmek istenen tahmin ufku kadar tekrarlanmasıyla daha uzun vadeli bulut hareketi tahminlerine ulaşılmıştır.

Bulutların görüntü üzerinde kaydırılması sırasında, her bir kaydırma adımında güneş olarak sınıflandırılmış piksellerin bulut pikselleri ile kesişme durumları incelenmiştir. Olası kesişme durumlarında, kaydırma tekrar sayısı baz alınarak güneşin önünün kapanacağı süreler tahmin edilmiştir. Güneş piksellerinin bulut pikselleri ile kesişme oranları yüzde olarak hesaplanmış ve her %5'lik kesişme durumu 1 birim olarak belirlenmiştir. Bu doğrultuda 0, güneşin önünün tamamen açık olduğunu, 20 değeri ise tamamen kapalı olduğunu ifade etmektedir. Böylelikle güneş önünün kapalı veya açıklık durumu yalnızca kapalı/açık şeklinde değil, yüzdelerle tahmin edilmiştir.

3.5 Güneş Işınımı Tahmini

Zamana göre sıralı değerler dizisinden oluşan veri türüne zaman serisi adı verilmektedir (Özhan 2020). Zaman serisi tahmin sistemleri ise geçmiş ve şimdiki durum bilgilerine dayanarak gelecekteki davranışları öngörmeye dayanmaktadır. Geçmişte zaman serisi problemlerinin çözümünde doğrusal istatistiksel yöntemler kullanılmaktayken,


günümüzde veri boyutunun artması ve beraberinde gelen karmaşıklık nedeniyle bu yöntemler yetersiz kalmaktadır. Ayrıca zaman serisi verilerinden manuel olarak etkin özelliklerin belirlenmesinin oldukça güç olmasından dolayı verilerdeki karmaşıklığı ve doğrusal olmayan ilişkileri öğrenme kabiliyetine sahip derin yapay sinir ağları (ANN) önerilmiştir (Ahmet 2019).

Derin yapay sinir ağları, makine öğrenimi uygulamalarında günümüzde oldukça yaygın şekilde kullanılmaktadır. Örneğin evrişimli sinir ağları (ESA), görüntü gibi matris formatındaki veri türlerini işlemek için yaygın şekilde kullanılırken, tekrarlayan sinir ağları ise dizi türündeki verileri işlemek için sıklıkla kullanılmaktadır. Geleneksel ANN'lerde girdi olarak yalnızca maruz kalınan mevcut örnekler dikkate alınırken, RNN'lerde ise mevcut girdilerin yanı sıra zaman içerisinde algıladıkları örnekler de girdi olarak kullanılmaktadır.


$x_i \in R^d$ olmak üzere $[x_1, x_2, x_3, \dots, x_k]$ şeklinde bir dizimiz olduğunu varsayarsak, RNN her adımda $[h_1, h_2, h_3, \dots, h_k]$ şeklinde bir gizli durum dizisi meydana getirmektedir. Gizli durumun t zamanındaki aktivasyonu, mevcut giriş x_t ve önceki gizli durum h_{t-1} 'in bir fonksiyonu olarak hesaplanmaktadır. Bu süreç denklem 3.16 ile ifade edilebilmektedir (İlyas 2020).

$$h_t = f(x_t, h_{t-1}) \quad (3.16)$$

Geleneksel ANN'ler aksine, RNN'lerin bir tekrar katmanı bulunmaktadır. Bu katman sayesinde ağ tarafından üretilen durum bilgisi depolanabilmekte ve giriş bilgisi ile ağa tekrar uygulanabilmektedir. Dolayısıyla RNN'lerde gerçekleştirilen hesaplamaları tutan bir hafıza bulunmaktadır. Şekil 3.2 ve 3.3'de sırasıyla örnek bir RNN ve bu ağın açık gösterimi görülebilmektedir (İlyas 2020).




Şekil 3.2 Tekrarlayan sinir ağının kapalı gösterimi (İnt. Kyn. 5).




Şekil 3.3 Tekrarlayan sinir ağının açık gösterimi (İnt. Kyn. 5).

İlk olarak 1997 yılında önerilen uzun kısa süreli bellek ağları (LSTM) veri üzerinde uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türüdür ve günümüzde zaman serisi tahminlerinde yaygın olarak kullanılmaktadır. RNN'lerde ANN'nin durum bilgilerinin saklanması ve aktarılması hedeflenmektedir. Fakat, durum bilgilerinin sürekli olarak işlenerek aktarılması nedeniyle uzun vadeli bağımlılıkların bozulmadan aktarılması mümkün olmamaktadır. Diğer bir deyişle, kısa vadeli bağımlılıkların başarılı bir şekilde aktarılmasına karşın, uzun vadeli aktarımlarda problemler oluşmaktadır. Bu sorunla başa çıkabilmek, dolayısıyla uzun vadeli bağımlılıkları başarılı bir şekilde aktarabilmek için LSTM'ler ortaya çıkmıştır (İlyas 2020).

Tüm RNN'ler birbirini sıralı olarak tekrar eden modüllerden oluşmaktadır. Standart RNN'lerde bu modüllerden her biri bir tanh veya benzer bir fonksiyondan oluşmaktadır. LSTM'lerde ise RNN'lerden farklı olarak her bir modül birbiriyle etkileşimde olan 4 ayrı yapıdan oluşmaktadır. LSTM'ler bu özelliğiyle RNN'lerden ayrılmaktadır. Şekil 3.4'de standart RNN modül yapısı, Şekil 3.5'de ise LSTM modül yapısı görülebilmektedir.



Şekil 3.4 Standart RNN modül yapısı (İnt. Kyn. 5).



Şekil 3.5 LSTM modül yapısı (İnt. Kyn. 5).

LSTM modülü sırasıyla unutmakapısı, giriş kapısı ve çıkış kapısı olmak üzere 3 ayrı kapıdan oluşmaktadır. Unutmakapıları, bilginin ne kadarının unutulacağı, ne kadarının bir sonraki aşamaya aktarılacağına karar vermektedir. Bunu gerçekleştirebilmek için 0 ve 1 aralığında çıkış üreten sigmoid (σ) fonksiyonundan yararlanılmaktadır. Değerin 0 olması durumunda bilgi tamamen unutulmakta ve aktarılmamakta, 1 olması durumunda ise bilginin tamamı diğer aşamaya aktarılmaktadır. W ağırlık, h gizli katman, h_t şu anki h değeri, h_{t-1} bir önceki h değeri, x_t şu anki girdi vektörü olmak üzere ilgili matematiksel ifade denklem 3.17’de verilmiştir (Görgel ve Kavlak 2020).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.17)$$

İlgili işlemin gerçekleştirilmesinin ardından hangi bilginin depolanması gerektiğine karar verilmektedir. Bu işlem, giriş kapısında bulunan sigmoid fonksiyonunun kullanılmasıyla gerçekleştirilmektedir. Tanh fonksiyonunun $\tilde{C}_t$ olarak ifade edilen aday değerlerin

vektörünü oluşturmamasından sonra bu iki süreç birleştirilir. İlgili aşamalara ait matematiksel ifadeler denklem 3.18 ve 3.19 da verilmiştir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.18)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.19)$$

Bu işlem sonrasında denklem 3.20’de gösterildiği gibi bir önceki C_{t-1} durumu yeni C_t durumuna güncellenmektedir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.20)$$

Son aşamada, hücre durumunun hangi kısımlarının çıktı olacağına karar veren ve denklem 3.21’de gösterilen bir sigmoid katmanı çalıştırılmaktadır. Ardından hücre durumu tanh katmanı vasıtasıyla sigmoid kapı çıktısıyla çarpılmakta ve böylelikle sadece karar verilen kısımlar çıktı olarak elde edilmektedir. İlgili denklem 3.22’de görülebilmektedir (Görgel ve Kavlak 2020).


$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.21)$$

$$h_t = \sigma_t * \tanh(C_t) \quad (3.22)$$

Gerçekleştirilen tez çalışmasında güneş ışıınımı tahmini için derin öğrenme yaklaşımlarından LSTM ağları kullanılmıştır. Derin öğrenme modelinin oluşturulmasında ise Keras kütüphanesinden yararlanılmıştır.

4. BULGULAR

Bu bölümde geliştirilen bulut hareketi ve güneş ışıınımı tahmin yaklaşımına ait çalışmalar ve elde edilen sonuçlardan bahsedilmiştir. Bu kapsamda bölüm 4.1’de gerçekleştirilen bulut hareketi takibi ve sonuçları, 4.2’de bulut, gökyüzü ve güneş tespitleri ve sonuçları, 4.3’de bulut hareketi tahminlerinin gerçekleştirilmesi ve elde edilen sonuçlar son olarak 4.4’de güneş ışıınımı tahmin modelinin oluşturulması, test edilmesi ve tahmin sonuçlarının değerlendirilme süreci aktarılmıştır. Çalışmalar Python programlama dili kullanılarak, spyder arayüzünde geliştirilmiştir. Geliştirme aşamasında numpy, opencv, math, sklearn kütüphanelerinden yararlanılmıştır. Yaklaşım takip, sınıflandırma ve tahmin olmak üzere üç ana aşamadan oluşmaktadır. Takip aşamasında bulut hareketleri takip edilmekte ve ortalama bulut hız ve yönleri hesaplanmaktadır. Sınıflandırma aşamasında bulut, gökyüzü ve güneş tespitleri gerçekleştirilmektedir. Son olarak tahmin aşamasında bulut hareketi ve güneş ışıınımı tahminlerine ulaşılmaktadır. Yaklaşımın ilk oluşturulma aşamasında, bulut hareketi takip ve tahmini için literatürde yer alan Wood-Bradley ve ark.’nın çalışmasından faydalanılmıştır (Wood-Bradley vd. 2012). Ardından, uygulama aşamasında görülen eksiklik ve geliştirilmeye açık yönlerin belirlenmesiyle yaklaşım geliştirilerek mevcut haline ulaşılmıştır. Tez kapsamında gerçekleştirilen yaklaşıma ait akış şeması ise Şekil 4.1’de paylaşılmıştır.



Şekil 4.1 Geliştirilen yaklaşıma ait akış şeması.

4.1 Bulut Hareketi Takibinin Gerçekleştirilmesi

Bu kısımda bulut hareketi takibinin gerçekleştirilme sürecinde yapılan çalışmalar ve elde edilen sonuçlar aktarılmıştır.

4.1.1 Kullanılan Gökyüzü Görüntüleri

Çalışmada gerçekleştirilen yaklaşımın geliştirilmesinde, Afyon Kocatepe Üniversitesi, Güneş ve Rüzgâr Enerjisi Uygulama ve Araştırma Merkezi'ne kurulan deney düzeneğinden edilen veriler kullanılmıştır. 1 Eylül 2021 – 1 Ekim 2021 tarihleri arasında toplanan verilerin incelenmesi sonucunda, gün içerisindeki bulut örtüsü çeşitliliği dikkate alınarak 9 Eylül 2021 tarihinde toplanan görüntü ve verilerin kullanılması kararlaştırılmıştır. İlgili tarihte sabah saatlerinde açık gökyüzü, öğle saatlerinde parçalı bulutlu gökyüzü, öğleden sonraki saatlerde ise kapalı gökyüzü durumları gözlenmiştir. Gün içerisinde farklı bulutluluk durumlarında yaklaşımın performansının değerlendirilmesi istenmiş, bu nedenle ilgili gün geliştirme aşamasında tercih edilmiştir. Bu kapsamda 10:00-16:00 saatleri arasında 10 saniyelik aralıklarla gökyüzü görüntüleri çekilmiş ve toplamda 2160 adet gökyüzü görüntüsü elde edilmiştir. Gökyüzü görüntülerinin oluşturacağı işlem yükü düşünülerek her bir gökyüzü görüntüsü 900x600 boyutuna indirgenmiştir. Şekil 4.2'de 9 Eylül 2021 tarihinde toplanan örnek gökyüzü görüntüleri görülebilmektedir. Bulut hareketleri takibinin 6 kare boyunca gerçekleştirilmesi (6x10 saniye toplamda 1 dakika) ve gelecek 30 karenin (30x10 saniye toplamda 5 dakikalık zaman ufku) tahmininin yapılması planlanmıştır. Bulgular kısmında paylaşılacak olan tüm sonuçlar bu parametreler için geçerlidir. Bulut hareketlerinin takip edileceği kare ve gerçekleştirilecek bulut hareketi tahmini kare sayıları kullanıcı tarafından değiştirilebilecek şekilde yaklaşım geliştirilmiştir. Dolayısıyla farklı kare sayılarında görüntü takibi ve tahmini gerçekleştirilebilmektedir.

Gökyüzü görüntüleri üzerinde gerçekleştirilecek tahminler tüm gün için planlanmıştır. Örnek olarak, güneş ışıınımı tahmini gerçekleştirilmek istenen güne ait ilk altı görüntüde bulut hareketi takipleri gerçekleştirilmiş, sonrasında gelen sıralı otuz görüntüde gerçekleştirilecek bulut hareketleri ve güneş önü açıklık/kapalılık durumları tahmin

edilmiştir. Ardından aynı işlemler otuz ve otuz altıncı gökyüzü görüntülerinde takip, sonraki otuz sıralı gökyüzü görüntüsünde tahmin şeklinde tekrarlanmıştır. Bu döngü bir gün içerisinde toplanan 2160 görüntü için gerçekleştirilmiştir. Tez kapsamında aktarılabilecek olan işlemler bir döngüde gerçekleştirilen işlemler olup, diğer döngülerde de aynı işlemler yeni görüntüler üzerinde tekrar edilmektedir.




Şekil 4.2 9 Eylül 2021 tarihinde deney düzeneği kullanılarak elde edilen gökyüzü görüntüsü örnekleri.

4.1.2 Öznitelik Noktalarının Tespitinin Gerçekleştirilmesi

Kullanılacak gökyüzü görüntülerinin belirlenmesinin ardından yaklaşımın ilk adımı olan öznitelik noktalarının belirlenmesi aşamasına geçilmiştir. Bu kapsamda ilk görüntü işleme alınarak kırmızı, mavi ve yeşil renk kanalları çıkartılmıştır. Ardından mavi renk kanalı ve kırmızı renk kanalının farkı alınarak mavi kırmızı fark görüntüsü elde edilmiştir. Mavi kırmızı fark görüntüsünde bulut hareketi takibi için önem arz eden bulut kenar ve köşeleri daha belirgin olmaktadır. Bu sayede Shi-Tomasi algoritmasının daha isabetli takip noktaları tespit edebilmesi amaçlanmıştır. Shi-Tomasi algoritmasının görüntü üzerine uygulanmasında OpenCV kütüphanesinde yer alan goodFeaturesToTrack() fonksiyonundan yararlanılmıştır. Şekil 4.3’de gökyüzü görüntüleri ve gökyüzü

görüntülerinde tespit edilen öznitelik noktaları görülebilmektedir. Fonksiyona ait parametreler ise Çizelge 4.1’de paylaşılmıştır.



Şekil 4.3 İki farklı gökyüzü görüntüsünde tespit edilen öznitelik noktalarının gösterimi.

Çizelge 4.1 goodFeaturesToTrack() fonksiyonu parametre değerleri.

Parametre	Değer
Maksimum bulunabilecek nokta sayısı	100
Kalite düzeyi	0,1
Noktalar arası minimum uzaklık	10
Blok Boyutu	10

Şekil 4.3 incelendiğinde, 9 Eylül 2021 tarihine ait 2 farklı gökyüzü görüntüsü görülebilmektedir. 1-A ve 2-A’da orijinal gökyüzü görüntüleri, 1-B ve 2-B’de ise tespit edilen öznitelik noktaları kırmızı işaretli olarak verilmiştir.

4.1.3 Öznitelik Noktalarının Takibinin Gerçekleştirilmesi


İlk görüntü üzerinde tespit edilen öznitelik noktalarının sıralı 5 kare boyunca takibi Lucas-Kanade optik akış yöntemi kullanılarak gerçekleştirilmiştir. Yöntemin uygulanmasında OpenCV kütüphanesinde yer alan `calcOpticalFlowPyrLK()` fonksiyonu kullanılmıştır. Fonksiyona girdi olarak takibin gerçekleştirilmek istendiği ilk görüntü, sıralı ikinci görüntü ve takip edilecek öznitelik noktalarına ait x, y koordinat bilgileri verilmektedir. Fonksiyon çıktısında ise ilk görüntüdeki öznitelik noktalarının yeni görüntüde bulundukları x, y koordinat bilgilerine ulaşılmaktadır. Fonksiyon girdisi olarak 1. ve 2. görüntülerin kullanılmasının ardından fonksiyon çıktısında bulunan yeni koordinat bilgileri 3. görüntü için saklanmıştır. Ardından 3. gökyüzü görüntüsü işleme dahil edilerek Lucas-Kanade optik akış algoritması 2 ve 3. sıralı görüntüler için saklanan koordinat bilgileri kullanılarak uygulanmıştır. Bu işlemin sıralı 6 görüntü boyunca tekrar edilmesiyle birlikte 1. görüntüde bulunan öznitelik noktalarının 6 kare boyunca takibi gerçekleştirilmiş olmaktadır. Öznitelik noktalarının her bir karede bulundukları geçmiş koordinat bilgileri de lineer regresyon doğrularının hesaplanmasında kullanılmak üzere kaydedilmektedir. Kullanılan fonksiyona ait parametre değerleri Çizelge 4.2’de paylaşılmıştır. Şekil 4.4’de ise Shi-Tomasi algoritması kullanılarak bulunan öznitelik noktaları ve bu noktaların sıralı 6 kare boyunca gerçekleştirmiş olduğu hareketler görülebilmektedir.

Çizelge 4.2 `CalcOpticalFlowPyrLK()` fonksiyonu parametre değerleri.

Parametre	Değer
Pencere Boyutu	100
Maksimum Düzey	0,1
Algoritma Durdurma Başarı Düzeyi (EPS)	10
Algoritma Kriter Sayısı	0,03

Şekil 4.4 1-A ve 2-A’da iki farklı gökyüzü görüntüsüne ait takibi gerçekleştirilecek öznitelik noktaları, 1-B ve 2-B’de ise 6 kare boyunca takibi gerçekleştirilmiş öznitelik noktalarının izledikleri yollar görülebilmektedir. 1-B ve 2-B’de bulunan kırmızı çizgiler

izlenilen yolu, yeşil noktalar ise öznitelik noktasının bulunduğu son konumu ifade etmektedir.



Şekil 4.4 İki farklı gökyüzü görüntüsünde tespit edilen öznitelik noktalarının takibinin gerçekleştirilmesi.

4.1.4 Bulut Ortalama Hız ve Yönlerinin Hesaplanması

Bulut hareketlerinin sıralı 6 görüntüde takibinin gerçekleştirilmesi ve konum bilgilerinin kaydedilmesi sonrasında bulutlara ait hız ve yönlerin bulunması gerekmektedir. Bu amaç doğrultusunda, her bir öznitelik noktası için 6 kare boyunca bulunduğu noktaları kesen bir lineer regresyon doğrusu hesaplanmıştır. Lineer regresyon doğrularının hesaplanmasında sklearn kütüphanesinde bulunan LinearRegression() fonksiyonundan yararlanılmıştır. Fonksiyona her bir öznitelik noktasına ait geçmiş 6 karede bulundukları x ve y koordinatları verilmiştir. Çıktı olarak öznitelik noktasının 6 kare boyunca

bulunduğu konumları maksimum ölçüde kesen lineer regresyon doğrusu elde edilmiştir. Ardından, regresyon doğruları tüm gökyüzü görüntüsü boyunca uzatılarak doğruların güneşi kesip kesmediği kontrol edilmiştir. Güneşi kesen doğrular tehlikeli olarak sınıflandırılmış ve bu doğrular üzerinde bulunan her bir bulut pikselinin ilgili öznitelik noktasının hesaplanan hız ve yön değeri kadar kaydırılmasıyla bulut hareketi tahminlerine ulaşılmıştır. Her bir öznitelik noktası için ayrı hız ve yön bulunmasıyla birlikte bulutların farklı yönde ve hızdaki hareketlerinin yakalanabilmesi mümkün olmuştur. Ancak, yalnızca öznitelik noktasının hareketi doğrultusunda bulunan bulut piksellerinin bulut hareketi tahmin sürecine dahil olması nedeniyle güneş önünü kapatabilecek bazı bulut hareketlerinin kaçırılabilirdiği ve güneş önü kapanma süresinin yanlış hesaplanabilirdiği görülmüştür. Bu problemlerin önüne geçebilmek amacıyla her bir öznitelik noktası için ayrı ayrı hız ve yön bilgilerinin hesaplanması yerine ortalama bulut hız ve yön bilgileri hesaplanmıştır.

Bu kapsamda regresyon doğrusu üzerinde öznitelik noktasının başlangıç konumu ile bitiş konumundaki x ve y koordinatları arasındaki farkların bulunmasıyla toplam x ve y koordinat düzeyindeki değişim vektörleri hesaplanmıştır. Hesaplanan değişimlerin takip gerçekleştirilen kare sayılarına bölünmesiyle de bir karede gerçekleştirdikleri x ve y düzlemindeki hareket vektörüne ulaşılmıştır. Son olarak tüm öznitelik noktalarının x ve y koordinatlarında gerçekleştirdiği hareketlerin ortalamaları alınarak tüm bulut hareketine ait tek bir ortalama hız ve yön bilgisine ulaşılmıştır. Ayrıca ilk görüntüden son görüntüye kadar takip süresi boyunca konumu değişmeyen öznitelik noktaları dikkate alınmayarak ortalama hız ve yön hesaplanması sürecinden çıkartılmıştır.

Hesaplanan ortalama hız ve yön bilgisinin gökyüzü görüntüsünde bulunan tüm bulut piksellerini kaydırmada kullanılmasıyla yalnızca lineer regresyon doğrusu üzerinde bulunan bulut pikselleri değil, tüm bulut kümesinin hareket tahmini gerçekleştirilmiştir. Şekil 4.5’de gerçekleştirilen bulut hareketi takibi ve tespit edilen tehlikeli doğrular görülebilmektedir. Tez çalışmasında gerçekleştirilen bulut hareketi tahminine ait görüntüler ise ilgili bölümlerde verilmiştir.



Şekil 4.5 Gerçekleştirilen bulut hareketi takibi (solda), tespit edilen tehlikeli doğrular (sağda).


4.2 Bulut, Gökyüzü ve Güneş Tespitlerinin Gerçekleştirilmesi

Bu kısımda gökyüzü görüntülerinde bulut, güneş ve gökyüzü tespitinin gerçekleştirilme sürecinde yapılan çalışmalar ve elde edilen sonuçlar aktarılmıştır.

4.2.1 Bulut ve Gökyüzü Tespiti

Literatürde gerçekleştirilen çalışmalarda bulut ve gökyüzü sınıflandırılmaları için yaygın olarak kırmızı/mavi oranı yöntemi kullanılmaktadır. Materyal metot kısmında da bahsedildiği gibi bu yöntemde her bir piksele ait kırmızı/mavi oranı bulunmakta ve belirli bir eşik değeri ile karşılaştırılmaktadır. Karşılaştırma sonucunda kırmızı/mavi oranının eşik değerinden büyük olduğu durumlarda ilgili piksel bulut, küçük olduğu durumlarda ise gökyüzü olarak sınıflandırılmaktadır. Sınıflandırma yönteminin başarısının seçilen eşik değerine bu denli bağlı olması eşik değerinin belirlenme sürecini oldukça kritik hale getirmektedir.


Bu tez çalışmasında, bir gün için kısa zaman ölçeklerinde gökyüzü görüntülerinin analizi ve güneş ışıınımı tahmini hedeflenmiştir. Dolayısıyla bulut ve gökyüzü sınıflandırma yönteminin gün içerisinde oluşabilecek farklı tüm gökyüzü ve bulut şartlarına uyum sağlayabilmesi ve etkili bir şekilde çalışması beklenmektedir. Gerçekleştirilen tez çalışmasında da bulut ve gökyüzü sınıflandırmaları için ilk olarak kırmızı/mavi yöntemi kullanılmıştır. Ancak kırmızı/mavi yönteminde yer alan sabit ve değişmeyen eşik değeri nedeniyle, yöntemin gökyüzünde gün boyunca oluşan tüm değişimlere ayak uyduramadığı, dolayısıyla belirli koşullar altında başarılı sınıflandırmalar gerçekleştiremediği görülmüştür. Şekil 4.6'da kırmızı/mavi oranı yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan bu problemlere ait 4 farklı örnek görülebilmektedir. A harfi ile orijinal gökyüzü görüntüleri, B harfi ile de kırmızı/mavi oranı yöntemi kullanılarak tespit edilen bulut ve gökyüzü görüntüleri verilmiştir. Görüntülerde kırmızılar bulutları, maviler ise gökyüzünü temsil etmektedir. İlgili şekil detaylı olarak incelendiğinde 1. görüntüde bulut olan belirli alanların gökyüzü olarak sınıflandırıldığı, 2. görüntüde sağ alt kısımdaki bulutların gökyüzü olarak sınıflandırıldığı, son olarak 3. ve 4. görüntülerde ise yine alt ve üst kısımlardaki belirli bulutların gökyüzü olarak sınıflandırıldığı görülebilmektedir.



Şekil 4.6 Kırmızı/mavi oranı yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler.

Yaşanan bu yanlış sınıflandırma problemlerinin önüne geçebilmek amacıyla çalışmamızda K-means kümeleme yönteminden yararlanılmıştır. K-means kümeleme yöntemi sayesinde her bir gökyüzü görüntüsü kendi içerisinde piksel düzeyinde analiz edilebilmekte ve bulut-gökyüzü olarak 2 sınıfa ayrılabilir. Her bir görüntünün piksel düzeyindeki değerlerinin kendi içerisinde analiz edilmesinden dolayı gökyüzü ve bulut durumları o an işlem gerçekleştirilen görüntü şartlarına göre değerlendirilebilmekte ve böylelikle daha doğru sınıflandırma sonuçları elde edilebilmektedir.

K-means kümeleme yöntemi kullanılarak bulut-gökyüzü sınıflandırmaları gerçekleştirme çalışmaları sırasında, K-means yönteminin de çok bulutlu, çok az bulutlu veya bulutsuz gökyüzü durumlarında sınıflandırmaları başarılı bir şekilde gerçekleştiremediği gözlenmiştir. Yöntemin bu gibi gökyüzü durumlarında iki farklı sınıfı net olarak algılayamaması sonucunda yanlış sınıflandırmaların yapıldığı düşünülmektedir. Şekil 4.7’de K-means kümeleme yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemlere ait 4 farklı örnek görülebilmektedir.




Şekil 4.7 K-means kümeleme yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler.


Şekil 4.7’de A harfi orijinal gökyüzü görüntülerini, B harfi ise K-means kümeleme yöntemi sonucunda sınıflandırılan bulut ve gökyüzüne ait görüntüleri göstermektedir.

Şekil detaylı olarak incelendiğinde, 1. ve 2. görüntüde bulut olmayan büyük bir alanın bulut olarak sınıflandırıldığı, 3 ve 4. görüntülerde ise bulut olan kısımlarda büyük oranda pürüzlü bir yapı oluştuğu görülebilmektedir.

Sonuç olarak, deneysel çalışmalar sonucunda az bulutlu, bulutsuz veya aşırı bulutlu hava koşullarında kırmızı/mavi oranı yönteminin, geriye kalan orta seviye bulutlu hava koşullarında ise K-means kümeleme yönteminin başarılı sonuçlar verdiği gözlenmiştir. İki farklı bulut-gökyüzü sınıflandırma yönteminin farklı şartlar altında başarılı sonuçlar vermesi nedeniyle çalışmamızda bulut-gökyüzü sınıflandırması için bu iki yöntemin birleşiminden oluşan hibrit bir sınıflandırma yaklaşımı kullanılması kararlaştırılmıştır. Oluşturulan yaklaşımda gökyüzü görüntüsü ilk olarak kırmızı/mavi oranı yöntemi ile bulut ve gökyüzü olarak sınıflandırılmaktadır. Ardından, tespit edilen bulut pikseli sayısının toplam görüntüde bulunan piksel sayısına oranlanmasıyla bulutluluk oranına ulaşılmaktadır. Hesaplanan bulutluluk oranının %10'den küçük (az bulutluluk veya bulutsuzluk durumu) veya %80'den büyük (çok bulutluluk durumu) olması durumunda bu gökyüzü şartlarında daha başarılı sınıflandırmalar gerçekleştiren kırmızı/mavi oranı yöntemi kullanılmıştır. Bulutluluk oranının %10 ve %80 arasında olduğu durumlarda ise K-means yöntemi kullanılarak bulut-gökyüzü sınıflandırmaları gerçekleştirilmiştir. Hibrit sınıflandırma yaklaşımı ile her iki yöntemin başarılı olduğu gökyüzü durumlarında kullanılması ve bu sayede daha yüksek doğruluk oranlarında bulut-gökyüzü sınıflandırmalarının gerçekleştirilmesi mümkün olmuştur. Şekil 4.8'de K-means kümeleme yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler ve hibrit sınıflandırma yaklaşımı sonuçlarına ait görüntüler, Şekil 4.9'da ise kırmızı/mavi oranı yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler ve hibrit sınıflandırma yaklaşımı sonuçlarına ait görüntüler görülebilmektedir. Şekil 4.8' de A harfi orijinal gökyüzü görüntülerini, B harfi K-means kümeleme yönteminde yaşanan problemlere ait görüntüleri, C harfi ise hibrit sınıflandırma yaklaşımı sonuçlarına ait görüntüleri göstermektedir. Şekil incelendiğinde 1-B'de gözükken bulut olmayan alanların bulut olarak algılanması sorununun 1-C'de çözüldüğü görülebilmektedir. Ayrıca yine 2-B' de bulunan yanlış tespitlerden dolayı oluşan pürüzlü yapının 2-C'de büyük oranda azaldığı görülebilmektedir.



Şekil 4.8 K-means kümeleme yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler ve hibrit sınıflandırma yaklaşımı sonuçları.




Şekil 4.9 Kırmızı/mavi oranı yöntemi ile gerçekleştirilmiş bulut/gökyüzü tespitlerinde oluşan problemler ve hibrit sınıflandırma yaklaşımı sonuçları.

Şekil 4.9’ da ise A harfi orijinal gökyüzü görüntülerini, B harfi kırmızı/mavi oranı yönteminde yaşanan problemlere ait görüntüleri, C harfi ise hibrit sınıflandırma yaklaşımı sonuçlarına ait görüntüleri göstermektedir. Şekil incelendiğinde 1,2 ve 3-B’de alt kısımda gözüken bulut olmayan alanların bulut olarak algılanması sorununun 1,2 ve 3-C’de çözüldüğü görülebilmektedir.

Hibrit sınıflandırma yaklaşımının oluşturulması sonrasında farklı gökyüzü görüntüleri üzerine gerçekleştirilen çalışmalar neticesinde kırmızı/mavi oranı yöntemi için eşik değeri 0,93 olarak belirlenmiştir. K-means yönteminde ise gökyüzü görüntülerinin farklı renk uzaylarına dönüşümleri gerçekleştirilmiş ve aynı görüntü için farklı renk uzayı kanalları elde edilmiştir. Elde edilen farklı renk uzayı kanalları K-means yöntemine girdi olarak verilerek bulut-gökyüzü sınıflandırma başarıları analiz edilmiştir. Analiz sonucunda, görüntülerin LAB uzayında bulunan a ve b renk kanallarının kullanılmasıyla en başarılı sınıflandırma sonuçları elde edildiği gözlenmiştir. Bu nedenle hibrit yaklaşımda K-means yönteminin kullanılacağı aşamalarda görüntüler ilk olarak LAB uzayına dönüştürülmekte, ardından a ve b renk kanallarına ait değerler K-means yöntemine girdi olarak verilmektedir.

Bulut ve gökyüzü sınıflandırmasının gerçekleştirilmesi aşamasında hibrit yaklaşımda kullanılan her iki yöntemde de güneş ve çevresinde bulunan parlak alan bulut olarak değerlendirilmekte ve bu şekilde sınıflandırılmaktadır. Güneşin görüntü üzerinde oluşturmuş olduğu yüksek parlaklık, sınıflandırmaların doğru bir şekilde yapılmasını oldukça zorlaştırmaktadır. Bulut hareketi tahminlerinin başarılı bir şekilde gerçekleştirilebilmesi ve yaklaşımın sağlıklı bir şekilde çalışabilmesi için sınıflandırmaların doğru bir şekilde yapılması gerekmektedir. Materyal metot kısmında da bahsedildiği gibi literatürde güneşin oluşturduğu bozucu etkilerin üstesinden gelebilmek için güneş takip sistemleri kullanılarak güneşin fiziksel yollarla engellenmesi sağlanabilmektedir. Bu sayede güneş ve çevresinde oluşan parlaklık engellenmekte ve görüntülerde sınıflandırmalar daha kolay ve başarılı bir şekilde gerçekleştirilebilmektedir. Ancak güneş takip sistemlerinin kullanıldığı bu çözüm oldukça maliyetli olabilmektedir. Literatürde güneşin oluşturduğu bu bozucu etkinin

ortadan kaldırılabilmesi amacıyla gerçekleştirilmiş birçok çalışma mevcuttur. Bu tez çalışmasında da güneş takip sistemlerinden yararlanılmamış, görüntülerde bulunan güneşin oluşturduğu bozucu etkiler görüntü işleme yöntemleriyle giderilmeye çalışılmıştır. Şekil 4.10'da güneşin bulut tespiti aşamasında oluşturduğu bozucu etkilere ait görüntüler görülebilmektedir. Burada A'lar orijinal gökyüzü görüntülerini, B'ler ise bulut, gökyüzü tespit görüntülerini ifade etmektedir. 2 farklı gökyüzü durumu için verilen B görüntüleri incelendiğinde güneşin bulut olarak yanlış tespit edildiği görülmektedir.



Şekil 4.10 Güneşin bulut tespiti aşamasında oluşturduğu bozucu etkiler (güneşin bulut olarak tespit edilmesi).

Gerçekleştirilen çalışmalarda ilk olarak güneşin oluşturduğu bozucu etkiler güneş merkezine tanımlanan bir maske yardımıyla aşılmaya çalışılmıştır. Önceden tanımlanan görüntülere ait güneş merkezi koordinatları kullanılarak güneş çevresinde daire şeklinde bir maske oluşturulmuş, bu maske yardımıyla güneş ve çevresinde bulunan tüm sınıflandırmalar kaldırılmıştır. Ancak bulunan bu çözümde güneş merkezli oluşturulan maskenin küçük tutulması durumunda güneş çevresi parlaklıklarının silinmeden bulut olarak sınıflandırılmış şekilde kalabildiği görülmüştür. Maskenin büyütülmesi


durumunda ise güneş yakınında bulunan gerçek bulut piksellerine ait sınıflandırmaların silinebildiği gözlenmiştir. Ayrıca güneşin bulutlar tarafından kapalı veya açıkta olma durumu değerlendirilemediği için güneş önünün kapalı olduğu durumlarda da güneş koordinatında maske içerisinde bulunan tüm bulut piksellerine ait sınıflandırmaların silinmesi durumu oluşmuştur. Dolayısıyla sınıflandırmalar doğru bir şekilde gerçekleştirilememiş ve bulut hareketi, güneş önü kapalılık/açıklık tahminlerinde yanlış sonuçlar görülmüştür. Oluşan bu yanlış sınıflandırmaların üstesinden gelebilmek amacıyla farklı yaklaşımlar geliştirilmiştir. İlgili bu yaklaşımlar 4.2.3 güneş yakını bulut ve gökyüzü tespiti gerçekleştirilmesi bölümünde aktarılmıştır.

4.2.2 Güneş Tespiti ve Güneş Önü Kapalılık/Açıklık Kontrolünün Gerçekleştirilmesi

Gökyüzü görüntülerinde bulunan güneşin tespit edilebilmesi için materyal metot kısmında da bahsedilen Yamashita vd. (2004) tarafından geliştirilen algorithmadan yararlanılmıştır. İlgili yöntemde, görüntünün kırmızı ve mavi kanalları kullanılarak elde edilen SI ve BI indis değerleri belirli değerlerle karşılaştırılmaktadır. Çalışmamızda SI ve BI indislerinin yanı sıra görüntünün HSV (renk, doygunluk, değer) renk uzayında bulunan h ve s katmanlarından da yararlanılmış ve belirli değerlerle karşılaştırılmıştır. Gerçekleştirilen analizler sonucunda güneşin en başarılı şekilde tespit edilebildiği SI, BI, h ve s değerleri Çizelge 4.3’de paylaşılmıştır. Ayrıca görüntüler üzerinde bulunan ve tespit edilen güneşe ait örnek 6 farklı gökyüzü görüntüsü Şekil 4.11’de verilmiştir.

Çizelge 4.3 Güneş tespitinde kullanılan renk uzayı parametreleri ve değerleri.

Parametre	Değer
SI	0
BI	170
h	0
s	0



Şekil 4.11 Gökyüzü görüntüleri üzerinde bulunan ve tespit edilen güneş konumları.


Şekil 4.11’de A harfi ile orijinal gökyüzü görüntüleri, B harfi ile de tespiti gerçekleştirilen güneş görüntüleri verilmiştir. Tespit edilen güneş bölümleri yeşil renk ile gösterilmiştir. 6 farklı gökyüzü durumu için örnek olarak verilen görüntüler incelendiğinde güneş konumunun başarılı bir şekilde bulunabildiği görülmektedir.

Güneş tespitinin gerçekleştirilmesi sonrasında güneşin açıkta, parçalı bulutlar arasında veya tamamen kapalı konumda bulunduğunu tespit edebilmek amacıyla Hough daire algılama yöntemi kullanılmıştır. Yöntemin uygulanabilmesi için ilk olarak tespit edilen ve güneş olarak sınıflandırılan pikseller sıfırlardan oluşan siyah bir maske üzerine aktarılmıştır. Siyah maske üzerinde yeşil renk ile tanımlanmış güneş piksellerinin oluşturduğu şeklin daire olup olmadığı Hough daire algılama yöntemi ile belirlenmiştir. Eğer güneş pikselleri daire şeklindeyse güneş açıkta, değilse bulutlar arasında şeklinde bir çıkarım yapılmıştır. Güneş sınıflandırması sonucunda tespit edilen güneş pikseli sayısının belirli bir eşik değeri altında olması durumunda ise güneşin bulutlar tarafından tamamen kapalı durumda olduğu sonucuna varılmıştır. Hough daire algılama yönteminin uygulanmasında OpenCV kütüphanesinde yer alan HoughCircles() fonksiyonundan yararlanılmıştır. Fonksiyonda daire bulunması zorluğunun değiştirilebildiği bir parametre bulunmaktadır. İlgili parametrenin yükseltilmesi daire bulma zorluğunu arttırmakta, düşürülmesi ise fonksiyonun daire bulmasını kolaylaştırmaktadır. Gerçekleştirilen

denemelerde, parametre değerinin nispeten düşük seçildiği, güneşin bulutların arasında olduğu durumlarda, güneş olarak sınıflandırılan piksellerin oluşturduğu şeklin daire olmamasına karşın fonksiyonun daire olarak tespit edilebildiği görülmüştür. İlgili sıkıntının çözülebilmesi için parametre değerinin arttırıldığı durumlarda ise güneşin açıkta olmasına karşın dairenin net bir daire olarak algılanmaması nedeniyle daire tespiti gerçekleştirilememiş, dolayısıyla güneş bulutlar arasında değerlendirmesine ulaşılmıştır. Bu sıkıntının önüne geçebilmek amacıyla “bulut ve gökyüzü sınıflandırması” başlığında açıklanmış olan bulutluluk oranı dikkate alınarak ilgili parametrenin değeri belirlenmiştir. Düşük bulutluluk oranlarında daire bulma zorluğu düşürülmüş, yüksek bulutluluk oranlarında ise daire bulma zorluğu arttırılmıştır. Böylelikle güneş olarak tespit edilen piksellerin şeklinde oluşan bozuklukların dikkate alınma durumu bulutluluk oranına göre belirlenmiştir. Gerçekleştirilen analizler sonucunda bulutluluk oranının %18’den küçük olduğu durumlarda daire bulma zorluğu düşürülmüş, büyük olduğu durumlarda ise daire bulma zorluğu arttırılarak en başarılı çalışma şartları sağlanmıştır. Fonksiyonun uygulanmasında kullanılan parametre değerleri Çizelge 4.4’de verilmiştir. Görüntülerde tespit edilen güneşler ve gerçekleştirilen güneş önü kapalılık/açıklık kontrolü Şekil 4.12’de görülebilmektedir. A harfi ile orijinal gökyüzü görüntüleri, B harfi ile tespit edilen güneşe ait güneş tespit görüntüleri ve C harfi ile güneş önü kapalılık/açıklık kontrolünün gerçekleştirileceği görüntüler verilmiştir. Şekil incelendiğinde, 1-C görüntüsünde Hough daire algılama yöntemi ile tespit edilen ve kırmızı ile işaretlenen daire görülebilmektedir. 2-C görüntüsünde ise herhangi bir daireye rastlanmamış, güneş bulutların arkasında olarak değerlendirme yapılmıştır.

Çizelge 4.4 HoughCircles() fonksiyonunda kullanılan parametreler ve değerleri.

Parametre	Değer
Minimum Uzaklık	50
Parametre 1	30
Parametre 2 (Daire Bulma Zorluğu Parametresi)	Bulutluluk Oranı < 18: 7 Bulutluluk Oranı >18: 12
Minimum Yarıçap	12
Maksimum Yarıçap	25



Şekil 4.12 Güneş önü kapalılık/açıklık kontrolünün gerçekleştirilmesi.

Güneşin tamamen kapalı durumda olduğu, yani güneş olarak sınıflandırılan piksel sayısının belirli bir eşik değerinin altında olduğu durumlarda ise daha önceden kullanıcı tarafından tanımlanmış güneş merkezi koordinatları kullanılmaktadır. Bu sayede güneşin görüntü üzerindeki konumuna ulaşılabilmekte ve alanda oluşturulan daire maskesi ile ilgili pikseller güneş olarak sınıflandırılabilir.

4.2.3 Güneş Yakını Bulut ve Gökyüzü Tespitinin Gerçekleştirilmesi

4.2.1 bulut ve gökyüzü tespiti bölümünde detaylı olarak bahsedildiği gibi güneş çevresi sınıflandırmalarının doğru bir şekilde gerçekleştirilebilmesi oldukça zorlu bir süreçtir. Bulut/gökyüzü sınıflandırma yöntemlerinin yüksek parlaklık nedeniyle bulut olarak sınıflandırdığı güneş çevresinin gerçekten bulutlu olup olmadığının anlaşılabilmesi, böylelikle sınıflandırmaların doğru bir şekilde gerçekleştirilebilmesi büyük önem arz etmektedir. Bu kapsamda gerçekleştirilen deneysel çalışmalarda, güneş çevresinde


bulunan parlaklık ve gerçek bulut piksellerinin farklı bir renk haritası ve ilgili renk haritasına ait h ve v kanallarının kullanılmasıyla birbirinden ayırt edilebileceği belirlenmiştir.

Bu amaç doğrultusunda ilk olarak gökyüzü görüntüsüne OpenCv kütüphanesinde yer alan “jet” renk haritası uygulanmıştır. Bu sayede, görüntüde yer alan piksellerin parlaklık seviyelerine göre maviden kırmızıya doğru renklendirilmesi sağlanmıştır. Ardından, güneş çevresini içerisine alacak boyutlarda güneş merkezli dairesel bir maske oluşturulmuştur. Oluşturulan maske dışında kalan tüm alanlara ait piksel değerleri sıfıra eşitlenmiş, böylelikle güneş ve çevresi dışında tüm piksellerin siyah olduğu gökyüzü görüntüsüne ulaşılmıştır. Son olarak elde edilen görüntü HSV renk uzayına dönüştürülmüş ve h ve v kanalları K-means yönteminde kullanılmak üzere çıkartılmıştır. Şekil 4.13’de iki farklı örnek gökyüzü görüntüsünde güneş yakını bulut tespiti aşamaları görülebilmektedir. Burada A harfi ile orijinal gökyüzü görüntüleri, B harfi ile orijinal gökyüzü görüntülerine jet renk haritası uygulanmış versiyonları, C harfi ile güneş çevresinin maskelenmiş versiyon görüntüleri ifade edilmiştir.

H ve v renk kanallarının çıkartılması sonrasında, K-means yönteminin kullanılıp kullanılmayacağını belirlemek amacıyla güneş önünün bulutlar tarafından tamamen kapalı konumda olup olmadığı araştırılmıştır. Hough daire algılama yöntemi sonucu, tespit edilen güneş ve bulut pikselleri sayısı gibi parametrelerin kullanılmasıyla güneş önü tamamen kapalılık durumu incelenmiş ve değerlendirilmiştir. Çizelge 4.5’de verilen koşulların sağlanması durumunda güneş önünün tamamen kapalı olduğuna karar verilmiştir.

Çizelge 4.5 Güneş önü tamamen kapalı değerlendirmesinin gerçekleştirilmesi.

Parametre	Değer
Hough daire algılama yöntemi sonucunda bulunan daire sayısı	0
Güneş Pikseli Sayısı	<650 ya da >950
Bulut Pikseli Sayısı	>6500




Şekil 4.13 Gökyüzü görüntülerinde güneş yakını bulut tespiti aşamaları.


Güneş önünün tamamen kapalı olduğuna karar verilmesi durumunda, oluşturulan maske içerisinde bulunan tüm pikseller bulut olarak sınıflandırılmıştır. Aksi durumda ise güneş önünün tamamen veya parçalı olarak açık olduğu değerlendirilmesi yapılmış ve sınıflandırmaların gerçekleştirilebilmesi için K-means kümeleme yönteminden yararlanılmıştır. Bu yöntemle birlikte, güneş yakın çevresinde bulunan gökyüzü ve gerçek bulut piksellerinin doğru bir şekilde sınıflandırılabilmesi amaçlanmıştır. K-means sınıflandırmasının gerçekleştirilebilmesi için ilk olarak maske kullanılarak oluşturulan görüntü HSV renk uzayına taşınmış ve h ve v kanalları çıkartılmıştır. Çıkartılan kanalların kullanılmasıyla güneş çevresi için ayrı bir K-means sınıflandırması gerçekleştirilmiştir.

K-means yönteminde kullanılacak sınıf sayısı parametresi “Güneş Yakını Bulut ve Gökyüzü Tespitinin Gerçekleştirilmesi” alt başlığında aktarılan güneşin açıkta veya bulutlar arasında olması durumlarına göre belirlenmiştir. Gerçekleştirilen deneysel çalışmalarda, güneşin açıkta olduğu durumlarda K-means sınıf sayısının 3, bulutlar arasında olduğu durumlarda ise 2 olarak belirlenmesiyle daha başarılı tespitler gerçekleştirilebildiği gözlenmiştir. Bu sebeple ilgili durumlara göre sınıf sayısının

belirlenmesi uygun görülmüştür. Sınıflandırma sonucunda, güneş merkezinde yer alan K-means sınıfından farklı sınıflara sahip pikseller silinmekte, yani gökyüzü olarak etiketlenmektedir. Böylelikle güneş çevresinde bulunan ve parlaklık nedeniyle bulut olarak yanlış bir şekilde sınıflandırılmış piksellerin sınıflandırmaları gökyüzü olarak düzeltilmektedir. Güneş merkezinde bulunan ve K-means sınıfıyla aynı sınıfa sahip pikseller ise, güneş olarak tespit edilip edilmediğine bakılarak sınıflandırılmaktadır. Eğer ilgili piksel güneş sınıflandırması aşamasında güneş pikseli olarak sınıflandırılmışsa güneş pikseli olarak kalmakta, sınıflandırılmamışsa bulut pikseli olarak sınıflandırılmaktadır. Bu sayede güneş çevresinde bulunan güneş, bulut ve gökyüzü sınıfları doğru bir şekilde belirlenebilmektedir. Şekil 4.14’de az bulutlu 3 farklı gökyüzü görüntüsü, Şekil 4.15’de ise çok bulutlu 3 farklı gökyüzü görüntüsü için güneş çevresinde gerçekleştirilen sınıflandırma sürecine ait görüntüler verilmiştir.



Şekil 4.14 Az bulutlu gökyüzü durumlarında güneş çevresinde gerçekleştirilen sınıflandırma aşamalarına ait örnekler.




Şekil 4.15 Çok bulutlu gökyüzü durumlarında güneş çevresinde gerçekleştirilen sınıflandırma aşamalarına ait örnekler.

Şekil 4.14 ve Şekil 4.15’de A ile ifade edilen görüntüler orijinal gökyüzü görüntülerini, B ile ifade edilen görüntüler güneş yakını için bulut tespiti gerçekleştirilmemiş görüntüleri, C ile ifade edilen görüntüler güneş çevresinde gerçekleştirilen K-means kümeleme yöntemi görüntülerini ve D ile ifade edilen görüntüler ise nihai bulut, güneş ve gökyüzü tespitinin gerçekleştirildiği görüntüleri göstermektedir. Şekil 4.14’de 3 farklı gökyüzü durumu için de güneş, bulut ve gökyüzü tespitlerinin başarılı şekilde gerçekleştirildiği görülebilmektedir. Şekil 4.15’de ise 3 farklı gökyüzü durumunda ufak hatalar haricinde tespitlerin büyük oranda başarılı şekilde gerçekleştirilebildiği görülmektedir.

4.3 Bulut Hareketi Tahmininin Gerçekleştirilmesi

Bu kısımda bulut hareketi tahmininin gerçekleştirilme sürecinde yapılan çalışmalar ve elde edilen sonuçlar aktarılmıştır. Bu kapsamda, “bulut hareketi tahmini” ve “bulut

ortalama hız ve yönlerinin hesaplanması” başlıklarında detayları verilmiş olan yöntemlerin ve elde edilen bilgilerin kullanılmasıyla bulut hareketi tahminlerine ulaşılmıştır. Bulut hareketi tahminleri 3 dakikalık zaman ufkunda ($30 \text{ kare} \times 10 \text{ sn} = 300 \text{ sn}$), 10 sn çözünürlükte gerçekleştirilmiştir. Daha önceden de belirtildiği gibi hareket takibi ve tahmini gerçekleştirilecek kare sayısı kullanıcı tarafından ayarlanabilmektedir. Tahminlerin gerçekleştirilmesi öncesinde, gökyüzü görüntülerinde alt kısımlarda bulunan bina vb. gibi görüntüde istenmeyen kısımların çıkartılması amacıyla bir maskeleme işlemi gerçekleştirilmiştir. Bu sayede bulut olarak sınıflandırılmış, ancak gerçekte bulut olmayan kısımlar bulut hareketi tahmini aşamasından çıkartılmıştır. İlgili maskeye ait örnek bir görüntü Şekil 4.16’da verilmiştir.




Şekil 4.16 İstenmeyen kısımların atılması için kullanılan tahmin maskesi.

Gerçekleştirilecek tahminler için ilk olarak her bir pikselin bulutluluk durumu incelenmiştir. İncelemesi gerçekleştirilen pikselin bulut olması durumunda, daha önceden hesaplanmış olan ortalama x ve y eksenindeki hareket değişimleri kadar pikselin kaydırılması gerçekleştirilmiştir. Kaydırma işlemi pikselin eski konumunun gökyüzü, hesaplanan yeni konumunun ise bulut olarak ayarlanmasıyla gerçekleştirilmektedir. Pikselin eski x konumuna x eksenindeki ortalama değişimin, eski y konumuna ise y eksenindeki ortalama değişimin eklenmesiyle pikselin yeni konumu hesaplanmaktadır. Hesaplanan yeni konumun görüntü boyutlarının dışında bulunması durumunda pikselin eski konumu gökyüzü olarak ayarlanmakta ancak yeni konumu için herhangi bir işlem gerçekleştirilmemektedir. Her bir bulut pikseli için kaydırmaların gerçekleştirilmesinin

ardından gelecek 10. saniyeye ait bulut hareketi tahminine ulaşılmış olmaktadır. 20. saniyede gerçekleşecek bulut hareketi tahminlerine ulaşabilmek için ise 1 kare için hesaplanan ortalama x ve y eksenindeki değişim değerleri 2 ile çarpılarak piksel kaydırmaları gerçekleştirilmiştir. Bahsedilen kaydırma işlemi her aşamada yeniden hesaplanan x ve y eksenindeki değişim değerleri ile tekrarlanmıştır. Ayrıca her bir kaydırma işlemi sonrasında bulut piksellerinin güneş pikselleri ile kesişme durumları incelenmiştir.

Tez çalışmasının ilk aşamalarında kesişme durumları yalnızca “kesişme var” ya da “kesişme yok” şeklinde değerlendirilmiştir. Bu şartlarda güneş önünün çok ufak bir kısmının veya tamamının kapalı olması durumları eşit şekilde değerlendirilmektedir. Ancak güneşin bulutlar tarafından çok ufak oranlarda kapanması ile tamamen kapanması arasında güneş ışıınımı değeri açısından büyük farklılıklar görülebileceği farkedilmiştir. Örneğin güneş önünün neredeyse açık olarak değerlendirilebileceği bir güneş önü kapalılık durumunda güneş ışıınımı değerinde büyük değişimler gözlenmezken tamamen kapalılık durumunda ise yüksek değişkenliklerin oluşabildiği görülmüştür. Bu problemin üstesinden gelebilmek amacıyla güneş önü kapalılık yüzdesi hesabı gerçekleştirilmiş ve kullanılmıştır. Bu kapsamda gerçekleştirilen her bir kaydırma işlemi sonrasında güneş pikseli sayısının, güneş pikselleriyle kesişen bulut pikseli sayısına oranlanması sonucunda belirli bir güneş önü kapalılık yüzdesine ulaşılmıştır. Kesişme kontrollerinin gerçekleştirilmesi aşamasında güneş önü açık veya kapalı değerlendirmelerinden yararlanılmıştır. Güneşin önünün açık olması durumunda kesişme kontrolü için tespit edilen güneş pikselleri kullanılırken, kapalı olması durumunda ise kullanıcı tarafından güneş merkezinde oluşturulmuş güneş maskesi kullanılmıştır. Hesaplanan güneş önü kapalılık yüzdesinin her bir %5’lik kesişme durumu 1 birim olarak kabul edilmiştir. Bu doğrultuda 0, güneşin önünün tamamen açık olduğunu, 20 değeri ise tamamen kapalı olduğunu ifade etmektedir. Kesişen piksel sayısının 35’den düşük olduğu durumlarda güneş önü kapalılık yüzdesi 0 olarak kabul edilmiştir. Deneysel çalışmalar sonucunda bahsedilen kaydırma ve güneş önü kapalılık yüzdesi hesaplama işlemleri belirlenen kaydırma tekrar sayısı kadar (30 kare) gerçekleştirilmiş ve böylelikle 300 saniyelik zaman ufkunda 10 saniye çözünürlüğe sahip bulut hareketi tahminlerine ulaşılmıştır. Şekil 4.17’de bulut hareketi tahmin aşamasında gerçekleştirilen işlemlere ait süreç sıralı ve detaylı olarak verilmiştir. Öznitelik noktalarının belirlenmesinden bulut hareketi

tahminine kadar oluşan bu sürecin sıralı görüntüler üzerinde tekrarlanmasıyla tüm güne ait bulut hareketi tahminlerine ulaşılmıştır. Görüntülerde her bir kaydırma aşamasında bulutların bulunması öngörülen pikseller farklı bir renk ile gösterilmiştir. Tahminin son aşamasında bulut piksellerinin bulunması öngörülen konumları kırmızı renk ile gösterilmiştir.




Şekil 4.17 Sıralı 6 gökyüzü görüntüsü kullanılarak gerçekleştirilen bulut hareketi tahminine ait tüm süreçler.


Şekil 4.17 1-A’da orijinal gökyüzü, 1-B’de takip edilecek öznelilik noktaları, 1-C’de 6 kare boyunca takibi gerçekleştirilen öznelilik noktaları, 1-D’de bulut, gökyüzü, güneş tespitleri, 1-E’de orijinal gökyüzü görüntüsüne uygulanmış jet renk haritası, 1-F’de güneş yakını için gerçekleştirilmiş K-means kümeleme yöntemi, 1-G’de nihai bulut, gökyüzü, güneş tespiti ve son olarak 1-H’de bulut hareketi tahmini görüntüleri verilmiştir. Böylelikle süreç içerisinde gerçekleştirilen tüm işlemlere ait görüntüler Şekil 4.17’de sıralı olarak sunulmuştur. Ayrıca Şekil 4.18’de çok az bulutlu ve Şekil 4.19’da az bulutlu, Şekil 4.20’de orta seviye bulutlu ve Şekil 4.21’de çok bulutlu olmak üzere farklı gökyüzü

durumları için gerçekleştirilen bulut hareketi tahminlerine ait görüntüler görülebilmektedir.


Şekil 4.18, 4.19, 4.20 ve 4.21’de ise A harfi ile orijinal gökyüzü görüntüleri, B harfi ile gerçekleştirilen bulut, gökyüzü, güneş tespiti görüntüleri, C harfi ile de gerçekleştirilen bulut hareketi tahmini görüntüleri verilmiştir. C harfi ile belirtilen bulut hareketi tahmini görüntülerinde her bir tahmin adımı farklı bir renk ile sembolize edilmiştir. Kırmızı renk bulutların son bulunacağı konumun tahminini göstermektedir. Şekil 4.20 2-A’da güneşin önünde bulunan bulut algoritma tarafından algılanabilmiş, bu sayede güneşin bulunduğu konum yeşil olarak değil, kırmızı olarak işaretlenmiştir. Ayrıca Şekil 4.21 2-A ve 2-B’de de güneşin önünün kapalı olduğu algılanabilmiş, böylelikle başarılı bulut hareket tahminleri gerçekleştirilebilmiştir.




Şekil 4.18 Çok az bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.



Şekil 4.19 Az bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.




Şekil 4.20 Orta seviye bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.



Şekil 4.21 Çok bulutlu gökyüzü durumlarında gerçekleştirilen bulut hareketi tahminleri.

Bulut hareketi takip ve tahminini gerçekleştirecek algoritmanın oluşturulmasının ardından tez çalışması kapsamında güneş ışınlı tahmini gerçekleştirilmesi hedeflenen 9 Eylül 2021 tarihi için bulut hareketi tahminlerini gerçekleştirme aşamasına geçilmiştir. Bu amaç doğrultusunda gerçekleştirilen bulut hareketi tahminleri ve gerçek değerler Şekil 4.22’de verilmiştir.

Şekil 4.22’de bulut hareketi tahmin değerleri kullanılarak hesaplanan güneş önü kapalılık değerleri ve gerçek güneş önü kapalılık değerlerinin karşılaştırması görülebilmektedir. Sonuçlar incelendiğinde, güneş önünün kapanacağı zaman dilimleri ve oranlarının büyük oranda başarılı bir şekilde tahmin edilebildiği görülmektedir. Bununla birlikte, tahmin değerlerinin başarısız olduğu anlardaki gökyüzü görüntülerinin incelemesi sonucunda bu kısımlardaki başarısızlığı açıklayabilecek birkaç tespitte bulunulmuştur. Bu tespitler aşağıda maddeler halinde belirtilmiştir.



Şekil 4.22 9 Eylül 2021 tarihi için gerçekleştirilen bulut hareketi tahminleri.

- Gerçekleştirilen bulut hareketi tahminleri için belirlenen tahmin ufkunun büyük olması nedeniyle takip süresince gökyüzü görüntülerinde yer almayan bulutlar daha sonraki görüntülerde belirebilmektedir. Bu nedenle takip esnasında güneş önüne geçebilecek bulut o an için saptanamamakta, dolayısıyla güneş önü açık olarak tahmin edilmektedir. Benzer şekilde takip süresince gökyüzü görüntülerinde bulunan bulutlar daha sonraki görüntülerde kaybolabilmekte, bu nedenle güneş önü kapanacak şeklinde tahminler gerçekleştirilebilmektedir. İlgili sıkıntıların tahmin zaman ufkunun küçültülmesiyle çözülebileceği düşünülmektedir.
- Gökyüzünde hareket halinde bulunan bulut kümelerinin genellikle ortalama bir hız ve yönleri bulunmaktadır. Ancak, bulutların doğası gereği zaman zaman farklı yön ve hızlarda hareket edebilen bulut kümeleri de gözlenebilmektedir. Dolayısıyla gökyüzü görüntüleri takibi süresince hesaplanan ortalama hız ve yön doğrultusunda ilerlemeyen bulut kümeleri tahmin sürecinde hatalara sebep olabilmektedir.
- Bulut, gökyüzü tespiti aşamasında gerçekleştirilen yanlış tespitler sonucunda bulut kaydırma sürecinde hatalar oluşabilmekte, dolayısıyla yanlış tahminler yapılabilmektedir.

Bulut hareketi tahmini aşamanın tamamlanmasının ardından bir sonraki aşama olan güneş ışıınımı tahmininin gerçekleştirilmesi aşamasına geçilmiştir.

4.4 Güneş Işınımı Tahmininin Gerçekleştirilmesi


Bu bölümde oluşturulan LSTM tahmin modelinin geliştirilme sürecine ait aşamalar ve gerçekleştirilen güneş ışıınımı tahmin sonuçlarına yer verilmiştir. Bu kapsamda bölüm 4.4.1’de LSTM modelinin oluşturulmasında kullanılan veri seti ve veri setinin hazırlanma süreci, 4.4.2’de tahmin modelinin oluşturulması, 4.4.3’de kullanılan hata metrikleri ve son olarak 4.4.4’de güneş ışıınımı tahmin sonuçları ve gerçekleştirilen değerlendirmeler aktarılmıştır.

4.4.1 Ağın Eğitimi için Gerekli Verilerin Hazırlanması


Tez çalışması kapsamında oluşturulacak LSTM tahmin modelinin eğitim ve testlerinin gerçekleştirilmesi için ilk olarak toplanan 1 aylık veriler incelenmiş ve gün içi bulutluluk durumları değerlendirilmiştir. Gün içerisinde bulutluluk gözlenmeyen veya sürekli kapalı bulutluluk durumunda bulunan günler çalışma kapsamına dahil edilmemiştir. Değerlendirmeler sonucunda, verilerin toplandığı ilk saatlerde açık, ardından parçalı bulutlu ve son olarak kapalı gökyüzü durumlarında bulunan 2 farklı gün tespit edilmiş ve çalışmada kullanılmasına karar verilmiştir. Böylelikle, gün içerisinde 3 farklı bulutluluk durumunun bulunduğu günlerin kullanılmasıyla geliştirilen yaklaşımın performansını daha etkin şekilde değerlendirilebilmiştir. Sonuç olarak, güneş ışıınımı tahminleri bulut hareketi tahminlerinin yapıldığı 9 Eylül 2021 tarihi saat 10:00-16:00 aralığı için gerçekleştirilmiştir. LSTM modelinin eğitimi için ise 20 Eylül 2021 tarihi saat 10:00-16:00 aralığındaki veriler kullanılmıştır. İlgili günlere ait ölçülen güneş ışıınımı değerleri 10’ar saniyelik çözünürlükte Şekil 4.23 ve 4.24’de verilmiştir.

Çalışmamızda gerçekleştirilen güneş ışıınımı tahminleri 5 dakikalık zaman ufku için 1’er dakikalık ışıınım ortalamaları kullanılarak gerçekleştirilmiştir. Bu nedenle 9 ve 20 Eylül tarihleri için 10’ar saniyelik zaman aralıklarında bulunan güneş ışıınımı verileri ve bulut hareketi tahminlerinin 1’er dakikalık ortalamaları hesaplanmıştır. Böylelikle her bir gün için 10:00-16:00 aralığında 360 ortalama güneş ışıınımı ve bulut hareketi tahmini değerlerine ulaşılmıştır. Modelin eğitiminde kullanılacak olan 20 Eylül 2021 tarihine ait gerçek bulut hareketi değerlerine ise ilgili güne ait her bir gökyüzü görüntüsü kullanılarak

ulaşılmıştır. Bu kapsamda her 10 saniyede bir toplanan gökyüzü görüntüsü üzerinde bulut, gökyüzü ve güneş sınıflandırmaları gerçekleştirilerek tespit edilen bulutların güneşin önünü kapatma oranları hesaplanmıştır. Ayrıca, bulut hareketi verilerinin yanında atmosfer dışı (extraterrestrial) güneş ışıınımı verileri de girdi olarak kullanılmıştır. Atmosfer dışı güneş ışıınımı verilerinin elde edilmesinde Ulusal Yenilenebilir Enerji Laboratuvarı (NREL) sayfasında yer alan güneş ışıınımı hesaplama aracından yararlanılmıştır (İnt. Kyn. 6). Sonuç olarak, atmosfer dışı güneş ışıınımı ve bulut hareketi tahmin değerlerinden oluşan 2 girdi ve ölçülen güneş ışıınımı değerlerinden oluşan 1 çıktının bulunduğu veri seti oluşturulmuştur. Girdi ve çıktı parametrelerinin istenilen zaman ölçeğinde ayarlanması sonrasında veri setinin eğitim ve test için hazırlanması aşamasına geçilmiştir.



Şekil 4.23 20 Eylül 2021 10:00-16:00 aralığında ölçülen güneş ışıınımı değerleri.



Şekil 4.24 9 Eylül 2021 10:00-16:00 aralığında ölçülen güneş ışıınımı değerleri.

Güneş önü kapalılığının artması durumunda güneş ışıınımı değeriinin düşmesi nedeniyle oluşan zıt orantıyı doğru orantıya çevirebilmek için bulut hareketi tahmin değeriileri maksimum değeriileri olan 20’den çıkartılmıştır. Böylelikle tahmin aşamasında 20 olarak tahmin edilen güneş önü kapalılık durumları 0 değeriine, 0 olarak tahmin edilen durumlar ise 20 değeriine dönüştürülmüştür. Ardından tüm girdi parametrelerinin aynı ölçeğe getirilebilmesi için normalizasyon işlemin uygulanmış ve değeriiler 0-1 aralığında normalize edilmiştir. Normalizasyon işleminin gerçekleştirilmesinde denklem 4.1’den yararlanılmıştır.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4.1)$$

Denkleminde X_{norm} normalize edilmiş değeri, X_{max} ilgili parametrenin en yüksek değeriini, X_{min} ise en küçük değeriini ifade etmektedir. Normalizasyon işleminin gerçekleştirilmesinin ardından eğitim veri seti eğitim ve doğrulamada (validation) kullanılmak üzere %80 ve %20’lik dilimlere ayrıştırılmıştır. Böylelikle veri setleri eğitim ve test için hazır hale getirilmiştir.

4.4.2 Tahmin Modelinin Oluşturulması ve Eğitiminin Gerçekleştirilmesi


LSTM tahmin modeli keras kütüphanesinin yerleşik LSTM ve dense katmanları kullanılarak oluşturulmuştur. Optimum sonucu elde etmek için yapılan denemelerde katman sayıları, her gizli katman/katmanlardaki nöron sayıları ve her katmanın aktivasyon fonksiyonları deneme yanılma metodu kullanılarak değiştirilmiştir. Sonuç olarak, LSTM tahmin modeli mimarisinin sırasıyla; bir girdi katmanı (input layer), 500 nörondan oluşan LSTM gizli katmanı (hidden layer), yığın normalleştirme (batch normalization) katmanı, 250 nörondan oluşan LSTM gizli katmanı, 0.2 oranında seyreltme (dropout) katmanı ve son olarak 1 nörondan oluşan dense katmanından oluştuğu durumda en iyi sonuçların elde edildiği görülmüştür. Gizli katmanlarda aktivasyon fonksiyonu olarak Relu kullanılmıştır. Girdi ile çıktı katmanlarının ilgili nöronları arasında ise kayıp fonksiyonu olarak Ortalama Hata Kareleri (mean squared

error – MSE) ölçütü kullanılmıştır. Kayıp fonksiyonu modelin hata oranını, diğer bir ifadeyle başarı oranını ölçmektedir. MSE, gerçek değer ile tahmin değeri arasındaki ortalama kare farkıdır ve Denklem 4.2’de verildiği şekilde formülize edilmektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2 \quad (4.2)$$

Denklem 4.2’de N örnek sayısını, o_i i. gözlem değerini ve p_i i. tahmin değerini ifade etmektedir.

Oluşturulan modelde optimizasyon algoritması olarak RMSprop kullanılmış ve öğrenme oranı (learning rate), zayıflama oranı (decay rate) sırasıyla $1e^{-4}$, $1e^{-6}$ olarak ayarlanmıştır. Ayrıca modelin öğrenme sürecinde döngü (epoch) sayısı 1000 ve yığın sayısı (batch size) 512 olarak belirlenmiştir. Öğrenme sürecindeki döngü sayısı aşırı öğrenmeyi önlemek amacıyla Keras kütüphanesinde yer alan erken durdurma (Early Stopping) ile sınırlandırılmıştır. Doğrulama veri setinde hesaplanan hata oranının 10 döngü boyunca azalmaması durumunda eğitim sonlandırılmıştır. Ağ yapısının oluşturulmasının ardından eğitim başlatılmıştır. Eğitim 965. döngüde erken durdurma şartının sağlanmasıyla durdurulmuştur. Ağın eğitimi sonucu oluşan hatanın iterasyona bağlı değişim grafiği, Şekil 4.25’de gösterilmiştir.



Şekil 4.25 Hatanın iterasyona bağlı değişimi.

4.4.3 Kullanılan Hata Metrikleri

Güneş ışıınımı tahmini için oluşturulan LSTM tahmin modelinin performansını değerlendirebilmek için 4 farklı istatistiki değerlendirme ölçütü kullanılmıştır. Bu ölçütler ve matematiksel ifadeleri aşağıda paylaşılmıştır.

- Ortalama Karekök Hata (Root Mean Square Error - RMSE): Genel olarak tahmin hatalarının standart sapmasını temsil etmektedir. Denklem 4.3 kullanılarak ifade edilmektedir (Ahmet 2019).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - p_i)^2}{N}} \quad (4.3)$$

- Ortalama Mutlak Hata (Mean Absolute Error - MAE): Gerçek değerler ile tahmin edilen değerler arasındaki farkın ortalama mutlak sapmasını belirtmektedir. Denklem 4.4 kullanılarak hesaplanmaktadır (Ahmet 2019).

$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - p_i| \quad (4.4)$$

- Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE): Modelin başarısını yüzdesel olarak hesaplamaktadır. Denklem 4.5 ile ifade edilmektedir (Ahmet 2019).

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{o_i - p_i}{o_i} \right| \quad (4.5)$$

- Belirleme katsayısı (Coefficient of Determination - r^2): Modellerin tahmin değerleri ile gerçek değerler arasındaki lineer ilişkinin gücünü temsil etmektedir ve 0 ile 1 aralığında değerler almaktadır. r^2 'nin 1'e yakın olması model uyumunun iyi olduğunu göstermektedir. Denklem 4.6 kullanılarak

hesaplanmaktadır. Denklemden bulunan $\bar{o}$ değeri ise gerçek gözlem değerlerinin ortalamasını ifade etmektedir (Ahmet 2019).


$$r^2 = 1 - \frac{\sum_{i=1}^N (o_i - p_i)^2}{\sum_{i=1}^N (o_i - \bar{o})^2} \quad (4.5)$$

4.4.4 Tahmin Modelinin Test Edilmesi

Bu kısımda, dakikalık ortalama güneş ışınlamı değeri tahmini için önerilen LSTM modelinin değerlendirilmesi ve performans analizi gerçekleştirilmiştir. İlgili amaç doğrultusunda, modelin başarısının test edilmesi için 9 Eylül 2021 tarihine ait veriler kullanılmıştır. Elde edilen tahmin sonuçları ile gerçek değerlerin karşılaştırılmasıyla ağın performansı analiz edilmiştir. Şekil 4.26’da 9 Eylül 2021 tarihinde 10:00-16:00 aralığında ölçülen 1 dakikalık ortalama güneş ışınlamı değeri ve geliştirilen yaklaşımın tahmin sonuçları görülebilmektedir. Ayrıca Şekil 4.27’de 0-1 aralığında normalize edilmiş güneş ışınlamı tahmini ve gerçek değerlerin yanında bulut hareketi değeri de görülebilmektedir. Hesaplanan hata metriklerine ait sonuçlar ise Çizelge 4.6’da verilmiştir.



Şekil 4.26 Gerçek güneş ışınlamı değeri ile model tahminlerinin karşılaştırılması.



Şekil 4.27 Tahmin ve gerçek değerlerle birlikte bulut hareket değerlerinin gösterimi.

Elde edilen sonuçlar incelendiğinde, tez çalışması kapsamında oluşturulan tahmin yaklaşımının başarılı sonuçlar verdiği görülebilmektedir. Işınım şiddetinde yaşanacak ani düşüşlerin bulut hareketi tahminleri sayesinde büyük oranda yakalanabildiği gözlenmiştir. Ancak, güneşin önünün belirli bir süre kapalı konumda kaldığı sürelerde modelin güneş ışıınımı değişimlerini tahmin etme konusunda yetersiz kaldığı görülmüştür.

Çizelge 4.6 Gerçekleştirilen tahmin için hesaplanan hata metrikleri.

Hata Metriği	Değer
RMSE	43.8499
MAE	28.5635
MAPE	14.1007
r^2	0.9433

Güneş önünün kapalı olmasına karşın bazı bulutların ince, bazı bulutların kalın yapıda bulunması güneş ışığını farklı oranlarda geçirmelerine sebep olmaktadır. Bu nedenle güneşin önünün kapalı olduğu sürelerde de bulut yapılarına bağlı olarak güneş ışıınımı değişimleri görülebilmektedir. Yaşanan bu problem nedeniyle tahmin modelinin ilgili alanlarda yetersiz kalabildiği düşünülmektedir. Bulut tiplerinin elde edilen gökyüzü görüntüleri kullanılarak sınıflandırılmaları sonucunda bu sıkıntının üstesinden gelinebileceği düşünülmektedir. Ayrıca, bulut hareketi tahminleri LSTM tahmin modeline girdi olarak verildiği için bulut hareketi tahmin başarısının artması güneş ışıınımı tahmin başarısını da olumlu yönde etkileyecektir.

5. SONUÇ ve ÖNERİLER

Yapılan tez çalışması kapsamında kısa vadeli bulut hareketi tahminleri gerçekleştiren, ardından elde edilen bulut hareketi tahminlerini kullanarak gün içi güneş ışıınımı tahminlerine ulaşılabilen bir derin öğrenme yaklaşımı geliştirilmiştir. Yaklaşım, bulut hareketi tahmini ve güneş ışıınımı tahmini olmak üzere 2 ana aşamadan oluşmaktadır. İlk aşamada 1 dakikalık bulut hareketleri izlenerek 5 dakikalık zaman ufku için 10'ar saniyelik bulut hareketi tahminleri gerçekleştirilmiştir. 2. aşamada ise ulaşılan bulut hareketi tahminleri ve atmosfer dışı ışıınım değerleri kullanılarak 5 dakikalık zaman ufku için 1 dakikalık ortalama güneş ışıınımı tahminleri gerçekleştirilmiştir. Yaklaşımın geliştirilmesi ve test edilmesinde Afyon Kocatepe Üniversitesi Güneş ve Rüzgâr Uygulama ve Araştırma Merkezine kurulan deney düzeneğinden elde edilen veriler kullanılmıştır. Geliştirilen yaklaşımın performansı 9 Eylül 2021 tarihine ait veriler kullanılarak test edilmiştir. Çalışma sonucunda şu sonuçlara ulaşılmıştır:

- Bulut hareketlerinin güneş ışıınımı değişiminde büyük etkiye sahip olduğu doğrulanmıştır. Güneş önünün bulutlar tarafından kapandığı durumlarda güneş ışıınımı değerinde ani düşüşler gözlenmiştir. Ters durumda bulutların güneşin önünden çekilmesiyle birlikte ışıınım değeri tekrar ani yükselişler sergilemiştir.
- Bulut hareketi takiplerinin Shi-Tomasi köşe algılama algoritması ve Lucas-Kanade optik akış yöntemlerinden yararlanılarak başarılı bir şekilde yapılabildiği belirlenmiştir. İlgili yöntemlere ek olarak doğrusal regresyon yönteminin kullanılmasıyla bulut ortalama hız ve yön bilgilerine ulaşılabilmiştir.
- Görüntülerde bulunan bulutların tespit edilmesi aşamasında belirli gökyüzü şartlarında yalnızca kırmızı/mavi oranı veya k-means kümeleme yönteminin kullanılmasının yetersiz kalabildiği gözlenmiştir. Çalışma kapsamında geliştirilen hibrit yaklaşım sayesinde bulut/gökyüzü sınıflandırmaları büyük oranda doğru olarak gerçekleştirilebilmiştir.

- Gökyüzü görüntülerinde güneşin çevresinde bulunan parlaklığın bulut tespit yöntemleri tarafından bulut olarak tespit edilebildiği ve bunun bulut hareketi tahmininde önemli sıkıntılara yol açabildiği gözlenmiştir. Bu sıkıntının önüne geçebilmek amacıyla tez çalışması kapsamında K-means kümeleme yönteminden yararlanılan yeni bir yaklaşım geliştirilmiştir. Geliştirilen yaklaşım ile birlikte güneş çevresinin parlaklığı ve güneş çevresinde gerçekten bulunan bulutların ayrımı başarılı şekilde yapılabilmektedir.
- Gökyüzü görüntülerinde güneşin ince bulutlar arkasında bulunması durumunda parlaklığını kaybetmediği, güneş tespit yöntemleriyle bulutların güneş olarak tespit edilebildiği gözlenmiştir. Bu sıkıntının üstesinden gelebilmek amacıyla Hough daire algılama yönteminden yararlanılan yeni bir çözüm geliştirilmiştir. İlgili çözüm sayesinde güneşin bulutlar arkasında veya açıkta olduğuna karar verilebilmiş, bu sayede daha başarılı bulut hareketi tahminleri gerçekleştirilebilmiştir.
- Bulutların güneşin önünü kapatma durumu yalnızca kapalı-açık şeklinde değerlendirilmemiş, belirli bir yüzde oranı hesaplanarak değerlendirme gerçekleştirilmiştir. Bu sayede güneşin önünü kapatan bulutun boyutu, bulutun güneşin önünü tamamen kapatma süresi gibi farklı durumların değerlendirilme imkânı oluşmuştur. Örneğin, bulutların güneşin önünde bulunduğu, ancak güneşin yarısının kapandığı veya çok küçük bir bulut parçasının güneşin önünde bulunduğu durumlar daha detaylı incelenip değerlendirilebilmiştir.
- Bulut hareketi tahminlerinde bulut takibi aşamasında hesaplanan ortalama hız ve yön bilgilerinin kullanılmasıyla tüm bulut kümesinin adım adım tahmini gerçekleştirilmiştir. Dolayısıyla yalnızca güneş önünü kesebilecek bulut kümelerinin değil, tüm bulut kümesinin tahmini gerçekleştirilmiştir.
- Güneş ışıınımı tahminleri için oluşturulan LSTM derin öğrenme modeli ile birlikte 43.8499 RMSE, 28.5635 MAE, 14.1007 MAPE ve 0.9433 r^2 performans metriği değerleriyle tahminler gerçekleştirilmiştir. Gün içerisinde dakikalık zaman ölçeğinde güneş ışıınımı değerinin sergilediği yüksek değişkenlikler ve beraberinde gelen tahmin zorluğu göz önünde

bulundurulduğunda yaklaşımın başarılı tahminler gerçekleştirilebildiği görülmektedir.

- Geliştirilen yaklaşımın eğitim ve testi için öğleden önce açık, öğle saatlerinde parçalı bulutlu, öğleden sonra ise kapalı gökyüzü şartlarında olan günler tercih edilmiştir. Bu sayede, oluşabilecek farklı gökyüzü durumlarında yaklaşımın göstereceği performansının incelenebilmesi hedeflenmiştir. Gün içerisinde bulutluluk yönünden yüksek değişkenliklerin bulunduğu zor şartlarda değerlendirilen yaklaşım performansının daha az değişkenliğe sahip günlerde artacağı öngörülmektedir.
- Çalışmada bir güne ait toplam 360 eğitim verisi ile ağ eğitimi gerçekleştirilmiştir. Farklı günlere ait verilerin çıkartılması ve bu sayının artması LSTM ağının daha iyi eğitilmesini sağlayacaktır. Ayrıca gökyüzü görüntülerinden güneş ışıınımı değerine etki edebilecek bulutluluk oranı, gökyüzü parlaklık ortalama değeri gibi bazı öznitelikleri de hesaba katmak, ağı daha iyi eğitebilmek ve daha doğru tahminler yapabilmek açısından faydalı olacaktır. İlerleyen zamanlarda bu konularda çalışmaların gerçekleştirilmesi planlanmaktadır.
- Bulut hareketi takibi aşamasında bulut takip süresinin arttırılmasıyla bulut hız ve yönlerinin daha yüksek doğruluklarla saptanabileceği öngörülmektedir. Ayrıca bulut hareketi tahmini için belirlenen zaman ufkunun kısaltılmasıyla bulut hareketi takibi daha sık aralıklarla tekrarlanabilecek böylelikle daha başarılı bulut hareketi tahminleri gerçekleştirilebilecektir.
- Çalışma kapsamında geliştirilen yaklaşımda bulutların yalnızca güneş önünü kapatma oranları ve süreleri değerlendirilerek güneş ışıınımı tahminleri gerçekleştirilmiştir. Ancak, güneş önünün belirli süreler aralığında tamamen kapalı olduğu durumlarda da güneş ışıınımı değişimleri devam edebilmektedir. Bu durumun güneşin önünü kapatan bulutların farklı güneş ışığı geçirme karakteristiklerine sahip olmasından dolayı oluştuğu öngörülmektedir. Örneğin; kapalı bir hava durumunda güneşin önüne kimi zaman kalın ve siyah yapıdaki bulutlar, kimi zaman ise ince ve beyaz yapıdaki bulutlar geçebilmektedir. İlerleyen çalışmalarda bulut tiplerinin de sınıflandırılarak tahmin sürecine dahil edilmesi planlanmaktadır.

6. KAYNAKLAR

- Aguiar L M, Pereira B, David M, Díaz F, Lauret P, 2015, Use of satellite data to improve solar radiation forecasting with Bayesian Artificial Neural Networks, *Solar Energy*, 122, 1309-1324.
- Ahmet K, 2019, Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7, 882-892.
- Akarıslan E, 2014, Güneş enerjisinin tahmininde sinyal işleme tabanlı yeni yaklaşımlar, *Eskişehir Osmangazi University, Master Degree*.
- Akarıslan E, Hocaoglu F O, Edizkan R, 2014, A novel MD (multi-dimensional) linear prediction filter approach for hourly solar radiation forecasting, *Energy*, 73, 978-986.
- Akarıslan E, Hocaoglu F O, 2016, A novel adaptive approach for hourly solar radiation forecasting, *Renewable Energy*, 87, 628-633.
- Akseker N, 2016, Tüm Gökyüzü Kamera Sistemi, 6. Uzaktan Algılama - CBS Sempozyumu (UZAL-CBS), Adana.
- Al-lahham A, Theeb O, Elalem K, A Alshawi T, A Alshebeili S, 2020, Sky imager-based forecast of solar irradiance using machine learning, *Electronics*, 9, 1700.
- Al-Shamisi M H, Assi A H, Hejase H A, 2013, Artificial neural networks for predicting global solar radiation in Al Ain city-UAE, *International journal of green energy*, 10, 443-456.
- Alonso-Montesinos J, Batlles F J, 2015, Solar radiation forecasting in the short-and medium-term under all sky conditions, *Energy*, 83, 387-393.
- Alzahrani A, Shamsi P, Dagli C, Ferdowsi M, 2017, Solar irradiance forecasting using deep neural networks, *Procedia Computer Science*, 114, 304-313.
- Ayodele T, Ogunjuyigbe A, Amedu A, Munda J, 2019, Prediction of global solar irradiation using hybridized k-means and support vector regression algorithms, *Renewable Energy Focus*, 29, 78-93.
- Barron J L, Fleet D J, Beauchemin S S, 1994, Performance of optical flow techniques, *International journal of computer vision*, 12, 43-77.

- Benmouiza K, Cheknane A, 2016, Small-scale solar radiation forecasting using ARMA and nonlinear autoregressive neural network models, *Theoretical and Applied Climatology*, 124, 945-958.
- Bracale A, Caramia P, Carpinelli G, Di Fazio A R, Ferruzzi G, 2013, A Bayesian method for short-term probabilistic forecasting of photovoltaic generation in smart grid operation and control, *Energies*, 6, 733-747.
- Caldas M, Alonso-Suárez R, 2019, Very short-term solar irradiance forecast using all-sky imaging and real-time irradiance measurements, *Renewable Energy*, 143, 1643-1658.
- Chang M-C, Yao Y, Li G, Tong Y, Tu P, 2017, Cloud tracking for solar irradiance prediction. 2017 IEEE International Conference on Image Processing (ICIP), IEEE: 4387-4391.
- Chen S, Gooi H, Wang M, 2013, Solar radiation forecast based on fuzzy logic and neural networks, *Renewable Energy*, 60, 195-201.
- Cheng H-Y, Yu C-C, Lin S-J, 2014, Bi-model short-term solar irradiance prediction using support vector regressors, *Energy*, 70, 121-127.
- Cheng H-Y, Yu C-C, 2015, Multi-model solar irradiance prediction based on automatic cloud classification, *Energy*, 91, 579-587.
- Cheng H-Y, 2017, Cloud tracking using clusters of feature points for accurate solar irradiance nowcasting, *Renewable Energy*, 104, 281-289.
- Chu Y, Pedro H T, Li M, Coimbra C F, 2015, Real-time forecasting of solar irradiance ramps with smart image processing, *Solar Energy*, 114, 91-104.
- Doodkorte P, 2021, Short-Term Irradiance Forecasting using All-Sky Images and Deep Learning.
- Fu C-L, Cheng H-Y, 2013, Predicting solar irradiance with all-sky image features via regression, *Solar Energy*, 97, 537-550.
- Gairaa K, Khellaf A, Messlem Y, Chellali F, 2016, Estimation of the daily global solar radiation based on Box-Jenkins and ANN models: A combined approach, *Renewable and Sustainable Energy Reviews*, 57, 238-249.
- Görgel P, Kavlak E, 2020, Uzun Kısa Süreli Hafıza ve Evrişimsel Sinir Ağları ile Rüzgar Enerjisi Üretim Tahmini, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11, 69-80.

- Heinle A, Macke A, Srivastav A, 2010, Automatic cloud classification of whole sky images, *Atmospheric Measurement Techniques*, 3, 557-567.
- Hocaoglu F O, Serttas F, 2017, A novel hybrid (Mycielski-Markov) model for hourly solar radiation forecasting, *Renewable Energy*, 108, 635-643.
- İlyas Ö, 2020, Uzun Kısa Dönem Bellek Ağlarını Kullanarak Erken Aşama Diyabet Tahmini, *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2, 50-57.
- Ji W, Chee K C, 2011, Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN, *Solar Energy*, 85, 808-817.
- Kenney C S, Zuliani M, Manjunath B, 2005, An axiomatic approach to corner detection. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), IEEE. 1: 191-197.
- Khosravi A, Koury R, Machado L, Pabon J, 2018, Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms, *Journal of Cleaner Production*, 176, 63-75.
- Lucas B D, Kanade T, 1981, An iterative image registration technique with an application to stereo vision, Vancouver, British Columbia.
- Marquez R, Coimbra C F, 2013, Intra-hour DNI forecasting based on cloud tracking image analysis, *Solar Energy*, 91, 327-336.
- Mecibah M S, Boukelia T E, Tahtah R, Gairaa K, 2014, Introducing the best model for estimation the monthly mean daily global solar radiation on a horizontal surface (Case study: Algeria), *Renewable and Sustainable Energy Reviews*, 36, 194-202.
- Mellit A, Benghanem M, Kalogirou S A, 2006, An adaptive wavelet-network model for forecasting daily total solar-radiation, *Applied energy*, 83, 705-722.
- Moghaddamnia A, Remesan R, Kashani M H, Mohammadi M, Han D, Piri J, 2009, Comparison of LLR, MLP, Elman, NNARX and ANFIS Models—with a case study in solar radiation estimation, *Journal of Atmospheric and Solar-Terrestrial Physics*, 71, 975-982.
- Mstafa R J, Younis Y M, Hussein H I, Atto M, 2020, A new video steganography scheme based on Shi-Tomasi corner detector, *IEEE Access*, 8, 161825-161837.
- Özhan E, 2020, Yapay Sinir Ağları ve Üstel Düzleştirme Yöntemi ile Türkiye'deki CO₂ Emisyonunun Zaman Serisi ile Tahmini, *Avrupa Bilim ve Teknoloji Dergisi*, 282-289.

- Pang Z, Niu F, O'Neill Z, 2020, Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons, *Renewable Energy*, 156, 279-289.
- Prasad R, Ali M, Kwan P, Khan H, 2019, Designing a multi-stage multivariate empirical mode decomposition coupled with ant colony optimization and random forest model to forecast monthly solar radiation, *Applied energy*, 236, 778-792.
- Příbyl B, Chalmers A, Zemčík P, 2012, Feature point detection under extreme lighting conditions. *Proceedings of the 28th Spring Conference on Computer Graphics*: 143-150.
- Qing X, Niu Y, 2018, Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM, *Energy*, 148, 461-468.
- Rabehi A, Guermoui M, Lalmi D, 2020, Hybrid models for global solar radiation prediction: a case study, *International Journal of Ambient Energy*, 41, 31-40.
- Renno C, Petito F, Gatto A, 2015, Artificial neural network models for predicting the solar radiation as input of a concentrating photovoltaic system, *Energy conversion and management*, 106, 999-1012.
- Rodríguez-Benítez F J, Arbizu-Barrena C, Huertas-Tato J, Aler-Mur R, Galván-León I, Pozo-Vázquez D, 2020, A short-term solar radiation forecasting system for the Iberian Peninsula. Part 1: Models description and performance assessment, *Solar Energy*, 195, 396-412.
- Schmidt T, Kalisch J, Lorenz E, Heinemann D, 2016, Evaluating the spatio-temporal performance of sky-imager-based solar irradiance analysis and forecasts, *Atmospheric chemistry and physics*, 16, 3399-3412.
- Scolari E, Sossan F, Haure-Touzé M, Paolone M, 2018, Local estimation of the global horizontal irradiance using an all-sky camera, *Solar Energy*, 173, 1225-1235.
- Shamshirband S, Mohammadi K, Chen H-L, Samy G N, Petković D, Ma C, 2015, Daily global solar radiation prediction from air temperatures using kernel extreme learning machine: A case study for Iran, *Journal of Atmospheric and Solar-Terrestrial Physics*, 134, 109-117.
- Sun H, Yan D, Zhao N, Zhou J, 2015, Empirical investigation on modeling solar radiation series with ARMA–GARCH models, *Energy conversion and management*, 92, 385-395.

- Trapero J R, Kourentzes N, Martin A, 2015, Short-term solar irradiation forecasting based on dynamic harmonic regression, *Energy*, 84, 289-295.
- Vecan D, 2011, Measurement and comparison of solar radiation estimation models for Izmir/Turkey: Izmir institute of technology case, Izmir Institute of Technology.
- Voyant C, Muselli M, Paoli C, Nivet M-L, 2012, Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation, *Energy*, 39, 341-355.
- Voyant C, Muselli M, Paoli C, Nivet M-L, 2013, Hybrid methodology for hourly global radiation forecasting in Mediterranean area, *Renewable Energy*, 53, 1-11.
- Voyant C, Darras C, Muselli M, Paoli C, Nivet M-L, Poggi P, 2014, Bayesian rules and stochastic models for high accuracy prediction of solar radiation, *Applied energy*, 114, 218-226.
- Wang S-Y, Qiu J, Li F-F, 2018, Hybrid Decomposition-Reconfiguration Models for Long-Term Solar Radiation Prediction Only Using Historical Radiation Records, *Energies*, 11, 1376.
- Watetakarn S, Premrudeepreechacharn S, 2015, Forecasting of solar irradiance for solar power plants by artificial neural network. 2015 IEEE Innovative Smart Grid Technologies-Asia (ISGT ASIA), IEEE: 1-5.
- Wood-Bradley P, Zapata J, Pye J, 2012, Cloud tracking with optical flow for short-term solar forecasting. Proceedings of the 50th Conference of the Australian Solar Energy Society, Melbourne, Citeseer.
- Yacef R, Mellit A, Belaid S, Şen Z, 2014, New combined models for estimating daily global solar radiation from measured air temperature in semi-arid climates: application in Ghardaïa, Algeria, *Energy conversion and management*, 79, 606-615.
- Yamashita M, Yoshimura M, Nakashizuka T, 2004, Cloud cover estimation using multitemporal hemisphere imageries, *International Archives of Photogrammetry, Remote Sens. Spat. Inf*, 35, 826-829.
- Yang D, Ye Z, Lim L H I, Dong Z, 2015, Very short term irradiance forecasting using the lasso, *Solar Energy*, 114, 314-326.
- Yu Y, Cao J, Zhu J, 2019, An LSTM short-term solar irradiance forecasting under complicated weather conditions, *IEEE Access*, 7, 145651-145666.

- Yuen H, Princen J, Illingworth J, Kittler J, 1990, Comparative study of Hough transform methods for circle finding, Image and vision computing, 8, 71-77.
- Zang H, Liu L, Sun L, Cheng L, Wei Z, Sun G, 2020, Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations, Renewable Energy, 160, 26-41.
- Zhang F, Gao Y, Bakos J D, 2014, Lucas-kanade optical flow estimation on the ti c66x digital signal processor. 2014 IEEE High Performance Extreme Computing Conference (HPEC), IEEE: 1-6.

İnternet Kaynakları

- 1- <https://www.enerjiportali.com/teias-ekim-2021-kurulu-guc-raporunu-yayimladi/>, 13.10.2021
- 2- <https://www.kippzonen.com/Product/12/CMP6-Pyrrometer> , 17.10.2021
- 3- https://www.canon.com.tr/for_home/product_finder/cameras/digital_slr/eos-80d/specification.html, 17.10.2021
- 4- <https://www.klasfoto.com.tr/urun/samyang-8mm-f3-5-umc-fish-eye-cs-ii-lens-nikon> , 18.10.2021
- 5- <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> , 25.10.2021
- 6- <https://midcdmz.nrel.gov/solpos/solpos.html>, 04.11.2021

Eşlik A H, Akarslan E, Hocaoglu F O, Sun Closeness/Clearance Estimation for 3 Different Days, In 2021 International Congress of Advanced Technology and Engineering (ICOTEN), pp. 1-5, IEEE, July, 2021.

Eşlik A H, Akarslan E, Hocaoglu F O, Güneş Işınım Verilerinin AKA / EEK-DVM Hibrit Yöntemi İle Analizi, International Symposium on Academic Studies in Science, Engineering and Architecture Studies, 2019

