

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

Kazım KABA

**TÜRKİYE İÇİN GÜNEŞLENME SÜRESİNİN UYDU
VERİLERİ VE COĞRAFİK PARAMETRELER
KULLANILARAK TAHMİN EDİLMESİ**

FİZİK ANABİLİM DALI

ADANA-2017

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TÜRKİYE İÇİN GÜNEŞLENME SÜRESİNİN UYDU VERİLERİ VE
COĞRAFİK PARAMETRELER KULLANILARAK TAHMİN EDİLMESİ**

Kazım KABA

DOKTORA TEZİ

FİZİK ANABİLİM DALI

Bu Tez 24/02/2017 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Oybirliği/Oyçokluğu ile Kabul Edilmiştir.

.....
Prof. Dr. H. Mustafa KANDIRMAZ
DANIŞMAN

.....
Prof. Dr. Süha BERBEROĞLU
ÜYE

.....
Prof. Dr. Mehmet Ali ÇULLU
ÜYE

.....
Prof. Dr. Kasım KURT
ÜYE

.....
Yrd. Doç. Dr. M. Zeki KURT
ÜYE

Bu Tez Enstitümüz Fizik Anabilim Dalında hazırlanmıştır.

Kod No:

**Prof. Dr. Mustafa GÖK
Enstitü Müdürü**

**Bu Çalışma Ç. Ü. Araştırma Projeleri Birimi Tarafından Desteklenmiştir.
Proje No: FDK-2015-4381**

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

ÖZ

DOKTORA TEZİ

**TÜRKİYE İÇİN GÜNEŞLENME SÜRESİNİN UYDU VERİLERİ VE
COĞRAFİK PARAMETRELER KULLANILARAK TAHMİN EDİLMESİ**

Kazım KABA

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
FİZİK ANABİLİM DALI**

Danışman : Prof. Dr. H. Mustafa KANDIRMAZ
Yıl: 2017, Sayfa: 116
Jüri : Prof. Dr. H. Mustafa KANDIRMAZ
: Prof. Dr. Süha BERBEROĞLU
: Prof. Dr. Mehmet Ali ÇULLU
: Prof. Dr. Kasım KURT
: Yrd. Doç. Dr. M. Zeki KURT

Bu çalışmada, destek vektör makineleri (DVM) yöntemiyle uydu görüntüleri ve coğrafik veriler kullanılarak Türkiye için günlük ve aylık güneşlenme süresi (GS) tahmin edilmeye çalışılmıştır. Çalışmada ilk olarak GS'ni etkileyen atmosferik ve coğrafik parametrelerin veri setleri günlük ve aylık olarak oluşturulmuştur. Bu veri setleri sabit yörüngeli Meteosat uydusuna ait SEVIRI sensörünün termal kanalları, kutupsal yörüngeli Suomi-NPP VIIRS sensörünün solar kanalları ile atmosfer dışı güneş ışınımı, gün uzunluğu, güneş saat açısı, deklinasyon açısı, julien günü, konum (enlem, boylam, yükseklik) ve zaman (yıl, ay, gün) olmak üzere günlük 27 ve aylık 26 farklı parametreyi içermektedir. Bu değişkenler arasından en uygun seçimler yapılarak günlük ve aylık modellerin girdileri tespit edilmiştir. DVM modelleri içerisinde en uygun fonksiyon ve parametreler kullanılarak her piksel için GS tahminleri gerçekleştirilmiştir. Modellerin eğitim ve test sonuçları için hata hesaplamaları yapılarak sonuçlar analiz edilmiş ve tüm Türkiye'yi kapsayacak şekilde 600 m yersel çözünürlükte günlük, aylık ve yıllık GS haritaları oluşturulmuştur.

Anahtar Kelimeler: Destek vektör makineleri, Güneşlenme süresi, Meteosat SEVIRI, Suomi-NPP VIIRS, Türkiye

ABSTRACT

PhD THESIS

ESTIMATION OF SUNSHINE DURATION BY USING SATELLITE DATA AND GEOGRAPHIC PARAMETERS OVER TURKEY

Kazım KABA

**ÇUKUROVA UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF PHYSICS**

Supervisor : Prof. Dr. H. Mustafa KANDIRMAZ
Year: 2017, Pages: 116
Jury : Prof. Dr. H. Mustafa KANDIRMAZ
: Prof. Dr. Süha BERBEROĞLU
: Prof. Dr. Mehmet Ali ÇULLU
: Prof. Dr. Kasım KURT
: Asst. Prof. Dr. M. Zeki KURT

In this study, support vector machine (SVM) method was applied to estimate the daily and monthly sunshine duration (SD) over Turkey. Firstly, daily and monthly datasets of atmospheric and geographical parameters which were assumed to affect the SD were constructed. These datasets were composed of 27 daily and 26 monthly different parameters which includes the thermal channels of the geostationary orbiting Meteosat SEVIRI sensor, the solar channels of the polar orbiting Suomi-NPP VIIRS sensor and extra-terrestrial solar radiation, day length, sun hour angle, declination angle, julien day number, location (latitude, longitude, altitude) and time (year, month, day). Inputs of daily and monthly models were determined by using recursive feature elimination (RFE) algorithm which selects the most suitable parameters among the dataset. Using the most appropriate function and its parameters of SVM models, SD estimations were performed for the considered pixels. Errors were calculated for the training and test phases and results were analysed. Finally, the daily, monthly and yearly SD maps of Turkey were created with a 600 meters spatial resolution.

Key Words: Support vector machines, sunshine duration, Meteosat SEVIRI, Suomi-NPP VIIRS, Turkey

GENİŞLETİLMİŞ ÖZET

Güneşlenme Süresinin (GS'nin) alansal ve zamansal dağılımının doğru ölçülmesi, ölçüm yapılmayan alanlar için doğru tahmin edilmesi enerji, tarım ve hidroloji gibi uygulamalar için büyük önem taşır. GS Dünyada ve ülkemizde yer istasyonlarında noktasal olarak ölçülmektedir. İstasyon olmayan yerler için ise tahmin yapılmaktadır. Ülkemizde GS ölçümleri Meteoroloji Genel Müdürlüğü (MGM) tarafından yer istasyonlarında uzun yıllardır helyograf ile ve son yıllarda yeni dijital cihazlarla (Sunshine Duration Meter) yapılmaktadır. Ölçüm yapılan noktalar arasında kalan bölgeler için bu ölçüm değerlerini kullanan ekstrapolasyon ve interpolasyon yöntemleriyle tahmin yapılır. Uygulanan bu yöntemlerin sonuçları yüksek oranda hata içermektedir. Buradaki en büyük sorun istasyonların birbirine uzak olmasıdır. Eğer istasyonlar birbirine yeterince yakın değilse ölçüm yapılan noktayla farklı meteorolojik koşullara ve belki de farklı coğrafik koşullar nedeniyle çok farklı güneşlenme değerlerine sahip olabilir. Dolayısıyla istasyonlar arasında kalan bölgeler için GS'ni daha doğru tahmin edecek metoda ihtiyaç olduğu açıktır.

Uydularca kaydedilen veriler alansal süreklilik gösterdiği için bu veriler yardımıyla GS herhangi bir alan için büyük bir doğrulukla hesaplanabilir. Uydu veri sağlayıcıları tarafından kullanıcılara sunulan ilk seviye veri radyans (radiance) verisidir. Üretilen bütün ürünlerin temelinde radyans verisi bulunmaktadır. Uydu kanalının kayıt yaptığı dalga boyu aralığına göre radyans verisinden öncelikle yansıma (r) ve parlaklık sıcaklığı (BT) hesaplanmaktadır. Bu çalışmada günlük ve aylık GS'ni tahmin etmek amacıyla yansıma ve parlaklık sıcaklığı verilerini kullanan modeller geliştirilmiştir.

Çalışmada sabit yörüngeli Meteosat uydusunun SEVIRI ve kutupsal yörüngeli Suomi-NPP uydusundaki VIIRS algılayıcılarına ait kanal verileri kullanılmıştır. Çeşitli dalga boyunda kayıt yapan bu kanallar değişik yüzeylerde farklı değerler verdiği için tüm yer ve atmosfer içindeki durumlar dikkate alınmış olmaktadır. Çalışmada 7 tane SEVIRI kanalı ile 9 tane VIIRS kanal verisi

incelenerek bunlardan tahminler için en uygun olanları seçilmiştir. Seçilen bu kanal verileri aslında GS'nin tahmini için önemli olan bulut ve aerosol gibi farklı uydu ürünlerinin elde edilmesinde kullanılan kanallardır. Çalışmada uydu verilerinin yanı sıra GS'ni etkileyen atmosfer dışı güneş ışınımı, gün uzunluğu, güneş saat açısı, deklinasyon açısı, julien günü, coğrafik konum (enlem, boylam, yükseklik) ve zaman (yıl, ay, gün) tasarlanan modeller içerisinde kullanılmıştır.

Çalışmada, nispeten yeni sayılabilecek Destek Vektör Makineleri (DVM) kullanılmıştır. DVM değişkenler arasındaki örüntülerin bilinmediği veri setlerindeki sınıflama problemleri için önerilmiş bir makine öğrenme algoritmasıdır. Sınıflama, regresyon ve aykırı değer belirleme için kullanılabilen bir eğitici öğrenme yöntemidir. Eğitim verisinden öğrenme yaparak yeni veri üzerinde doğru tahmin yapmaya ve genelleştirmeye çalışan makine öğrenmesidir. İstatistiksel öğrenme teorisine ve yapısal risk minimizasyonuna dayanmaktadır. Doğrusal ve doğrusal olmayan problemlere uygulanabilmektedir. DVM'nin bir başka önemli özelliği ise veri seti hakkında ön varsayımda bulunmamasıdır.

Türkiye'de GS ölçümü yapılan 131 istasyona ait bilgiyle modeller için veri setleri oluşturulmuştur. Günlük tahmin için 45, aylık tahmin için ise 120 istasyon verisi kullanılmıştır. Üretilen veri setlerinden günlük veri seti 27, aylık veri seti 26 girdi parametreden oluşmaktadır. Başarılı tahminler için bu parametrelere özellik seçme algoritması uygulanarak en iyi girdi setleri oluşturulmuştur. Böylece DVM'nin daha uygun girdilerle etkin çalışması sağlanmıştır. Yüksek doğrulukta tahmin için DVM modelinin en uygun fonksiyon ve parametreleri belirlenmiştir. Veri setlerinin %70'i eğitim ve %30'u test aşamaları için kullanılmıştır.

Modeller eğitilerek test edilmiş ve tahmin için en doğru şartların tespit edilmesiyle tüm Türkiye'yi kapsayacak şekilde bütün pikseller için günlük ve aylık GS değerleri üretilmiştir. Türkiye'nin günlük, aylık ve yıllık GS haritaları 600 m çözünürlükte oluşturulmuştur. Oluşturulan bu haritalar birçok çalışmada girdi veri olarak kullanılabilir. Ayrıca bu model uydu görüntülerine uygulanabilir ve GS görüntüleri oluşturularak ürün haline getirilebilir.

TEŞEKKÜR

Bana bu çalışmayı öneren, çalışmalarımın her aşamasında yapıcı ve yönlendirici fikirleri ile bana daima destek olan ve her konuda yardımlarını esirgemeyen danışman hocam Sayın Prof. Dr. H. Mustafa KANDIRMAZ'a teşekkürlerimi sunarım.

Bu çalışmada kullanılan verilerin kısa sürede temin edilmesini ve verilerin işlenmesinde gereken belge ve bilgiyi sağlayan Meteoroloji Genel Müdürlüğü Uzaktan Algılama Şubesi çalışanı Sayın Erdem ERDİ'ye yardımlarından dolayı teşekkürlerimi sunarım.

Çalışmalarım sırasında bilgi, tecrübe ve görüşlerinden faydalandığım Sayın Doç. Dr. Mutlu AVCI'ya katkılarından dolayı teşekkürlerimi sunarım.

Laboratuvar imkânlarından faydalandığım Ç.Ü. Fen Edebiyat Fakültesi Fizik Bölümüne, maddi destek veren Ç.Ü. Bilimsel Araştırma Projeleri Birimi'ne (Proje No: FDK-2015-4381) teşekkürlerimi sunarım.

Maddi manevi destekleriyle daima yanımda olan aileme sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

SAYFA

ÖZ.....	I
ABSTRACT	II
GENİŞLETİLMİŞ ÖZET	III
TEŞEKKÜR.....	V
İÇİNDEKİLER.....	VI
ÇİZELGELER DİZİNİ.....	VIII
ŞEKİLLER DİZİNİ.....	X
SİMGELER VE KISALTMALAR	XII
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR	7
3. MATERYAL VE METOD	15
3.1. Materyal.....	15
3.1.1. Güneşlenme Süresi	18
3.1.2. Coğrafik Veriler.....	23
3.1.3. Sabit Yörüngeli (Geostationary) Meteosat Uyduları.....	25
3.1.3.1. SEVIRI Level 1.5 Verisi	31
3.1.4. Kutupsal (Polar) Yörüngeli Suomi-NPP Uydusu	33
3.1.4.1. VIIRS SDR Verisi	38
3.2. Metod.....	39
3.2.1. Öznitelik Seçimi	39
3.2.2. Destek Vektör Makineleri	41
3.2.3. Hata Hesabının Tanımlanması.....	47
4. BULGULAR VE TARTIŞMA.....	49
4.1. Yer ve Coğrafik Verilerin Hazırlanması	49
4.2. Sabit Yörüngeli Uydu Verilerinin Hazırlanması	53
4.3. Kutupsal Yörüngeli Uydu Verilerinin Hazırlanması	62
4.4. Modelin Oluşturulması.....	65

4.4.1. Günlük Güneşlenme Süresi	68
4.4.2. Aylık Güneşlenme Süresi	73
5. SONUÇLAR VE ÖNERİLER	81
KAYNAKLAR.....	87
ÖZGEÇMİŞ.....	95
EKLER	96



ÇİZELGELER DİZİNİ

SAYFA

Çizelge 3.1. Meteosat ikinci nesil uyduları	28
Çizelge 3.2. SEVIRI algılayıcısının bantları	29
Çizelge 3.3. VIIRS algılayıcısının özellikleri.....	34
Çizelge 3.4. VIIRS algılayıcısının bantları.....	36
Çizelge 4.1. Günlük tahmin için kullanılan istasyonlar.....	51
Çizelge 4.2. Çalışmada kullanılan SEVIRI kanalları	55
Çizelge 4.3. Çalışmada kullanılan VIIRS kanalları.....	63
Çizelge 4.4. Günlük modelin girdi parametreleri	68
Çizelge 4.5. Günlük modelin istatistiksel sonuçları	70
Çizelge 4.6. Aylık modelin girdi parametreleri.....	73
Çizelge 4.7. Aylık modelin istatistiksel sonuçları	76



ŞEKİLLER DİZİNİ

SAYFA

Şekil 3.1.	Campbell-Stokes helyografı (BOM).....	20
Şekil 3.2.	Campbell-Stokes helyograf diyagramları (PIERCECOLLEGE).....	21
Şekil 3.3.	CSD 1 dijital güneşlenme süresi ölçer (METOFFİCE)	22
Şekil 3.4.	Deklinasyon açısı ve yıllık değişimi (POWERFROMTHESUN)	23
Şekil 3.5.	Yer sabit yörüngeli Meteosat uydusunun şeması (MGM)	26
Şekil 3.6.	Verilerin üst boyutlu uzaya haritalanması (Fletcher, 2009).....	43
Şekil 3.7.	Lineer olmayan DVM (Granata ve ark, 2016)	46
Şekil 3.8.	DVM'nin mimarisi.....	47
Şekil 4.1.	Günlük tahminde kullanılan istasyonların konumları	50
Şekil 4.2.	Aylık tahminde kullanılan istasyonların konumları.....	50
Şekil 4.3.	Coğrafik verilerin yıllık değişimi.....	53
Şekil 4.4.	SEVIRI h5 dosyasının içeriği	54
Şekil 4.5.	SEVIRI 5, 6 ve 7. kanallara ait 10-bit ham radyans görüntüleri.....	56
Şekil 4.6.	SEVIRI 8, 9 ve 10. kanallara ait 10-bit ham radyans görüntüleri.....	57
Şekil 4.7.	SEVIRI 11. kanala ait 10-bit ham radyans görüntüsü.....	58
Şekil 4.8.	SEVIRI algılayıcısının 5, 6, ve 7. kanallarının koordinatlandırılmış parlaklık sıcaklığı görüntüleri	60
Şekil 4.9.	SEVIRI algılayıcısının 8, 9, ve 10. kanallarının koordinatlandırılmış parlaklık sıcaklığı görüntüleri	61
Şekil 4.10.	SEVIRI algılayıcısının 11. kanallının koordinatlandırılmış parlaklık sıcaklığı görüntüsü.....	62
Şekil 4.11.	VIIRS kanallarının yansıma görüntüleri.....	64
Şekil 4.12.	VIIRS RGB görüntüsü.....	65
Şekil 4.13.	Oluşturulan modellerin iş akışı	66
Şekil 4.14.	Günlük modelin eğitim ve test aşamalarının simülasyonu	69
Şekil 4.15.	Günlük modelin eğitim ve test aşamalarının dağılım grafikleri.....	69
Şekil 4.16.	Günlük modelin öğrenme eğrisi.....	70

Şekil 4.17. 01-01-2015 tarihli yansımaya, parlaklık sıcaklığı ve günlük güneşlenme süresi görüntüleri	71
Şekil 4.18. 18-07-2015 tarihli yansımaya, parlaklık sıcaklığı ve günlük güneşlenme süresi görüntüleri	72
Şekil 4.19. Aylık modelin eğitim ve test aşamalarının simülasyonu	74
Şekil 4.20. Aylık modelin eğitim ve test aşamalarının dağılım grafikleri.....	75
Şekil 4.21. Aylık modelin öğrenme eğrisi	75
Şekil 4.22. 2015 yılının Ocak, Şubat ve Mart aylarının güneşlenme süreleri	77
Şekil 4.23. 2015 yılının Nisan, Mayıs ve Haziran aylarının güneşlenme süreleri	78
Şekil 4.24. 2015 yılının Temmuz, Ağustos ve Eylül aylarının güneşlenme süreleri	79
Şekil 4.25. 2015 yılının Ekim, Kasım ve Aralık aylarının güneşlenme süreleri	80
Şekil 5.1. 2015 yılı Güneşlenme Süresi haritası.....	84

SİMGELER VE KISALTMALAR

GS	: Güneşlenme Süresi
DVM	: Destek Vektör Makineleri
MGM	: Meteoroloji Genel Müdürlüğü
NPP	: National Polar-Orbiting Partnership
VIIRS	: Visible Infrared Imaging Radiometer Suite
EUMETSAT	: European Organisation for the Exploitation of Meteorological Satellites
METEOSAT	: Meteorological Satellite
MSG	: Meteosat Second Generation
SEVIRI	: Spinning Enhanced Visible and Infrared Imager
SAFNWC	: Satellite Application Facility on Support to Nowcasting and Very Short-Range Forecasting
CM SAF	: Climate Monitoring Satellite Application Facility
MODIS	: Moderate Resolution Imaging Spectrometer
RBF	: Radial Basis Function
WMO	: World Meteorological Organization
SDR	: Sensor Data Records
RFE	: Recursive Feature Elimination
MBE	: Mean Bias Error
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
RMSE	: Root Mean Square Error



1. GİRİŞ

Güneşlenme süresi (GS) klimatoloji ve/veya klimatolojik tabanlı uygulamalarla, tarım, enerji, hidroloji gibi alanlarda yapılan çalışmalar için en önemli iklim verilerinden biridir (Wild ve ark, 2005; Suehrcke ve ark, 2013). Bunlara örnek vermek gerekirse; yüzeye gelen güneş enerjisinin hesaplanmasında birçok meteorolojik ve coğrafik parametre kullanılmasına rağmen en önemli parametre GS'dir (Trnka ve ark, 2005). GS bitkilerin ne kadar süreyle güneş enerjisine maruz kaldığı bilgisine bağlı olarak ürün (rekolte) tahminlerinde sıkça kullanılan bir veridir (Devanathan, 1975). Genel iklim değişiklerinin belirlenmesinde GS kritik önem taşır (Sanchez-Lorenzo ve ark, 2009). Fotovoltaik panellerin yerleştirileceği alanlar için yıllık GS belirli saatin üzerinde olan yerlerin tespit edilmesi önemli rol oynamaktadır (Jain ve ark, 2011). GS'nin alansal ve zamansal dağılımının doğru ölçülmesi, ölçüm yapılmayan alanlar için doğru tahmin edilmesi yukarıda sayılan uygulamalar için büyük önem taşır.

GS Dünyada ve ülkemizde yer istasyonlarında noktasal olarak ölçülmektedir. İstasyon olmayan yerler için ise tahminler yapılmaktadır. Ülkemizde GS ölçümleri Meteoroloji Genel Müdürlüğü (MGM) tarafından yer istasyonlarında uzun yıllardır helyograf ile ve son yıllarda yeni dijital cihazlarla (Sunshine Duration Meter) yapılmaktadır. Ölçüm yapılan noktalar arasında kalan bölgeler için bu ölçüm değerlerini kullanan ekstrapolasyon ve interpolasyon yöntemleriyle tahmin yapılır. Uygulanan bu yöntemlerin sonuçları yüksek oranda hata içermektedir. Bunun nedeni istasyonların birbirine belirli mesafeden uzak olmasıdır. Eğer istasyonlar birbirine yeterince yakın değilse ölçüm yapılan noktayla farklı meteorolojik koşullara ve belki de farklı coğrafik koşullar nedeniyle çok farklı güneşlenme değerlerine sahip olabilir. Dolayısıyla istasyonlar arasında kalan bölgeler için GS'ni daha doğru tahmin edecek metoda ihtiyaç olduğu açıktır.

GS'ni tahmin etmek için dünyanın farklı bölgesinden araştırmacıların çeşitli çalışmaları bulunmasına rağmen bu konudaki çalışmalar son derece

kısıtlıdır. Bu az sayıdaki çalışmaları da uydu verileri ve yer ölçümleri ile yapılan çalışmalar olmak üzere başlıca iki gruba ayırabiliriz (El-Metwally, 2005; Kandirmaz, 2006; Good, 2010; Mohandes ve Rehman, 2013). Çalışmalarda uydu verilerinin mekânsal ve zamansal sürekliliği nedeniyle kullanımı tercih edilmektedir. Atmosferimize, yer yüzeyine, okyanus ve buzullara yönelik değişik uydularda farklı algılayıcılara ait veriler bulunmaktadır. Bu veriler çeşitli çalışmalarda girdi olarak kullanılabilir. Uydu verileri içerisinde çeşitli amaçlar için kullanılmak üzere birçok ürün bulunurken, GS ürünü bulunmamaktadır ve bu eksikliğin giderilmesi gerekmektedir.

Uydu görüntüleriyle yapılan çalışmalarda araştırmacılar Heliosat denen ve yansıtma (reflectance) verisini kullanan metod ile GS'ni tahmin etmeye çalışmışlardır (Olseth ve Skartveit, 2001; Kandirmaz, 2006; Good, 2010; Shamim ve ark, 2012; Bertrand ve ark, 2013; Kandirmaz ve Kaba, 2014). Heliosat yönteminde, uydu yansıma verisini ve referans noktaların değerlerini kullanarak yeni noktalar için yapılan tahminler yeterli doğrulukta sonuç vermemektedir. Bir örnek vermek gerekirse kar ve bulut ayrımı yapılamadığı için bu yöntem karla kaplı alanlar için bulut varmış gibi düşük güneşlenme değeri vermektedir. Heliosat yöntemini geliştirmek amacıyla metodun sonraki versiyonlarında (Heliosat-4) aerosol, ozon, su buharı, bulut özellikleri gibi yeni parametreler kullanılmıştır. Metod bu haliyle enerji hesaplamalarında kullanılmaktadır fakat GS hesabı için uygulanmamıştır. Yine uydudan yapılan çalışmalarda GS tahmininde bulutluluk ve bulut tipi ürünleri kullanılan başka modeller de bulunmaktadır (Good, 2010; Kothe ve ark, 2013).

Bir bölgeye ait GS o bölge üzerinde atmosferdeki değişkenlerden özellikle bulut, sıcaklık, aerosol, su buharı ve coğrafik konum (enlem, boylam, yükseklik) ile yakından ilgilidir. Günümüzde bunlar gibi atmosferik değişkenler uydu kayıtlarından türetilmektedir. Uydularca kaydedilen veriler alansal süreklilik gösterdiği için bu veriler yardımıyla GS herhangi bir alan için büyük bir doğrulukla hesaplanabilir. Bulutun miktarı ve yapısı GS'ni direkt etkiler. Diğer önemli

etkenlerde havada bulunan aerosol ve su buharıdır. Bu verilerin ölçümleri farklı dalga boyunda kayıt yapan uydu kanal verileri kullanılarak elde edilir. Bu değerler uydu ürünü olarak kullanıcılara sunulmaktadır. Bu işlemler sırasında birtakım varsayım yapılmaktadır ve bu varsayımlar sonuçların hata içermesine neden olmaktadır. Bu kayıpların olumsuz etkilerini ortadan kaldırmak için daha temel seviye (daha az işlenmiş) verilerin kullanılması gerekmektedir.

Uydu veri sağlayıcıları tarafından kullanıcılara sunulan ilk seviye veri radyans (radiance) verisidir. Üretilen bütün ürünlerin temelinde bu radyans verisi bulunmaktadır. Uydu kanalının kayıt yaptığı dalga boyu aralığına göre radyans verisinden öncelikle yansımaya (r) ve parlaklık sıcaklığı (BT) hesaplanmaktadır. Bu çalışmada günlük ve aylık GS'ni tahmin etmek amacıyla yansımaya ve parlaklık sıcaklığı verilerini kullanan modeller geliştirilmiştir. Yansımaya verisi VIIRS (Visible Infrared Imaging Radiometer Suite) kanallarından, parlaklık sıcaklığı da SEVIRI (Spinning Enhanced Visible and Infrared Imager) kanallarından alınmıştır.

Bu çalışmada sabit yörüngeli Meteosat uydusunun SEVIRI ve kutupsal yörüngeli Suomi-NPP (National Polar-Orbiting Partnership) uydusundaki VIIRS algılayıcılarına ait kanal verileri kullanılmıştır. Çeşitli dalga boyunda kayıt yapan bu kanallar değişik yüzeylerde farklı değerler verdiği için tüm yer ve atmosfer içindeki durumlar dikkate alınmış olmaktadır. Çalışmada 7 tane SEVIRI termal kanalı ile 9 tane VIIRS kanal verisi incelenerek bunlardan tahmin için en uygun olanları seçilmiştir. Seçilen bu kanal verileri aslında GS'nin tahmini için önemli olan bulut, kar, aerosol ve su buharı gibi farklı uydu ürünlerinin elde edilmesinde kullanılan kanallardır. Çalışmada uydu verilerinin yanı sıra GS'ni etkileyen coğrafik parametrelerden atmosfer dışı güneş ışınımı, gün uzunluğu, güneş saat açısı, deklinasyon açısı, coğrafik konum (enlem, boylam, yükseklik) ile julien günü ve zaman (yıl, ay, gün) tasarlanan model içerisinde kullanılmıştır.

Son yıllarda araştırmacılar tarım, hidroloji ve meteoroloji gibi birçok alandaki problemleri çözmek için makine öğrenme algoritmalarını kullanmaktadır (Sen, 1998; Chapelle ve ark, 1999; Unal ve ark, 2003; Ch ve ark, 2014; Tehrany ve

ark, 2014; Ding ve Sun, 2015; Zheng ve ark, 2015). Özellikle son dönemlerde yapay sinir ağları (YSA) birçok alanda kullanıldığı gibi güneş enerjisi ve GS tahminlerinde de kullanılmakta ve tatmin edici sonuçlar ortaya çıkarmaktadır (Al-Alawi ve Al-Hinai, 1998; Eissa ve ark, 2013; Kandirmaz ve ark, 2014; Rahimikhoob, 2014; Yadav ve Chandel, 2014). Araştırmacılar, özellikle enerji hesaplamalarında çeşitli makine öğrenme algoritmalarının sonuçlarını karşılaştırmışlardır. Yapılan çalışmalarda nispeten yeni bir yöntem olan DVM'nin diğer algoritmalarından daha iyi sonuçlar verdiği belirtilmiştir (Ch ve ark, 2014; Javadi ve ark, 2015; Kaytez ve ark, 2015). Bu çalışmada da diğer makine öğrenme algoritmalarına göre avantajlarından dolayı DVM kullanılmıştır.

DVM değişkenler arasındaki örüntülerin bilinmediği veri setlerindeki sınıflama problemleri için önerilmiş bir makine öğrenme algoritmasıdır. Örüntü tanıma, sınıflama, regresyon ve aykırı değer belirleme için kullanılabilen bir eğitilmiş öğrenme yöntemidir. DVM Eğitim verisinden öğrenme yaparak yeni veri üzerinde doğru tahmin yapmaya ve genelleştirmeye çalışan makine öğrenmesidir. İstatistiksel öğrenme teorisine ve yapısal risk minimizasyonuna dayanmaktadır. Doğrusal ve doğrusal olmayan problemlere uygulanabilmektedir. Ayrıca DVM veri seti hakkında ön varsayımda bulunmaz (Cortes ve Vapnik, 1995; Vapnik ve ark, 1997; Vapnik, 1998; Ch ve ark, 2014).

Bu çalışmada kullanılmak üzere üretilen günlük veri seti 27 girdi parametreden, aylık veri seti ise 26 girdi parametreden oluşmaktadır. Başarılı bir model için girdilere özellik seçme yöntemi uygulanarak en iyi girdi setleri oluşturulmuştur. Başka bir deyimle veri setlerinde boyut indirgeme işlemi yapılmıştır. Uygun girdilerin belirlenmesi amacıyla lineer DVM fonksiyonunu kullanan yinelemeli özellik eleme (Recursive Feature Elimination) metodundan faydalanmıştır. Bu algoritma önemlilikleri önem sırasına göre sıralamaktadır. Bu sıralanmış parametrelerden günlük GS'ni tahmin etmek için en önemli 13 girdi, aylık GS'ni tahmin etmek için ise en önemli 10 girdi seçilmiştir.

Günlük tahmin için en uygun girdiler SEVIRI algılayıcısının 7, 9, 10 ve 11. kanalları, VIIRS algılayıcısının m04, m05, m07 ve m08 kanalları, atmosfer dışı güneş ışınımı, deklinasyon açısı, enlem, boylam ve ay numarası olmak üzere 13 girdi belirlenmiştir. Aylık tahmin için en uygun girdi parametreler, SEVIRI algılayıcısının 7 ve 9. kanalları, VIIRS algılayıcısının m02, m04, m05, m07 ve m08 kanalları ile atmosfer dışı güneş ışınımı, enlem ve boylam olmak üzere 10 girdi belirlenmiştir.

DVM ile yapılacak tahminler için günlük ve aylık veri setlerinin oluşturulmasıyla bu veri setlerinin %70'i eğitim, %30'u da test için ayrılmıştır. Bu aşamada modellerin başarısını etkileyen DVM'nin parametreleri araştırılmıştır. DVM için uygun çekirdek fonksiyonu RBF (Radial Basis Function) olarak tespit edilmiştir. Uygun parametrelerle DVM çalıştırılıp günlük ve aylık tahminler yapılmıştır. Tahminler için hata hesapları yapılarak modeller değerlendirilmiştir. Son adımda modeller görüntülerle çalışmakta ve bütün pikseller için GS tahmini yapılarak günlük ve aylık GS haritaları üretilmiştir. Hesaplanan aylık GS'nin ortalaması alınarak yıllık GS haritası oluşturulmuştur.



2. ÖNCEKİ ÇALIŞMALAR

Temel meteorolojik verilerden biri olan GS su, tarım, enerji ve iklim değişikliği konularında yaygın olarak kullanılmaktadır. GS verisi geniş kullanım alanına sahip olmasına karşın sadece yer istasyonlarında noktasal ölçüm ile elde edilmektedir. Diğer birçok meteorolojik verinin uydu ve/veya radar gibi alternatif kaynağı bulunurken bu durum GS için geçerli değildir. Bu konuda yapılan çalışmalar GS'nin tahmini ile alansal ve zamansal değişimi olarak iki grupta incelenmektedir. Dünya genelinde araştırmacılar GS'ni yer ölçümleri ve/veya uydu görüntüleri gibi farklı veri kaynakları ve değişik yöntemler kullanarak tahmin etmişlerdir. Geçmiş verilerle GS'nin değişimini inceleyen çalışmalarda geleceğe ait bilgiler vermektedir. Bu bölümde GS konusunda yapılan çalışmalar verilmiştir.

Aksoy (1999) Türkiye'de, Ankara için GS'nin değişimini analiz etmiştir. Çalışmada 1955-1996 yılları arasındaki saatlik GS'nin değişim (variation) ve eğilimi (trend) incelenmiştir. Yıllık bazda %7'lik somut bir değişim tespit edilmiştir. GS'de günün her saatinde azalma tespit edilmiş ve en fazla azalış gün doğumu ve gün batımında olduğu belirtilmiştir. Diğer meteorolojik parametrelerle GS'nin ilişkisi analiz edilmiş ve GS'ndeki değişim ve eğilimin bu meteorolojik parametrelerdeki değişimlerle açıklanabileceğini belirtmişlerdir.

Olseth ve Skartveit (2001) yaptıkları çalışmada Norveç ve Avrupa'daki bazı şehirler için Meteosat verilerinden GS'ni türetmişlerdir. Bunun için 1996-97 yıllarına ait Meteosat görüntülerinden Heliosat yöntemiyle üretilen açıklık indeksini kullanmışlardır. Bu indeks ile Norveç'te yedi ve Avrupa da beş yer istasyonu verilerini kullanarak güneşlenme süresinin gün uzunluğuna oranı olan aylık nispi GS'ni tahmin etmişlerdir.

Kaiser ve Qian (2002) Çin'de 1954-1998 yılları arasındaki GS'nin azalan trendini incelemiştir. Azalmanın çoğunun 1980'den sonra gerçekleştiği ve bunun atmosferik antropojenik aerosoldeki büyük artıştan kaynaklandığı belirtilmiştir. Dünyada ve Çin'de genel bir sıcaklık artışı olurken, Sichuan havzasında yaz

aylarında maksimum sıcaklığın azaldığını belirtmişlerdir. Bu bölge için GS değerlerinde büyük düşüşler, aerosol miktarında ise büyük artışlar olduğu belirtilmiştir.

El-Metwally (2005) Mısır'ın farklı bölgeleri için GS'ni ve global güneş ışınımını tahmin etmiştir. Çalışmada maksimum ve minimum sıcaklık ile bulutluluk verisini kullanarak aylık bağıl GS'ni lineer olmayan bir metod (logaritmik) ile hesaplamıştır. Çalışmada bu yöntemin düşük hatalı sonuçlar verdiği ve güneşlenme süresi verisi olmayan yerler için kullanılabilceği belirtilmiştir. Ayrıca bu yöntemle tahmin edilen nispi GS kullanılarak global güneş enerjisi tahmin edilmiştir. Bu metod, lineer yöntemlerle kıyaslanmış, farklı hava koşullarında (açık, parçalı, kapalı) mevsimsel olarak test edilmiş ve dünya genelinde 32 nokta için uygulanmıştır. Açık hava şartlarında yapılan tahminin doğruluğu yüksek iken bulutlu (kapalı) havalarda tahminin doğruluğunun düştüğü belirtilmiştir. Genel olarak bu yöntemin iyi sonuç verdiği ifade edilmiştir.

Matzarakis ve Katsoulis (2006) Yunanistan'da GS'nin yersel ve zamansal değişimini incelemiştir. Ayrıca mevsimsel ve yıllık GS'ni deneysel formül ile tahmin etmiştir. Tahmin ile ölçülen değerler arasındaki ilişkinin genelde iyi olduğu belirtilmiştir. Yıllık GS'nin Temmuzda maksimum, Ocak veya Aralık'ta minimum değerde olduğu verilmiştir. Mevsimsel ve yıllık GS'nin Yunanistan'ın iç dağlık bölgelerinde küçük değerler aldığı ve ege denizinin güney-batı adalarında ise yüksek değerli olduğu ifade edilmiştir.

Kandirmaz (2006) meteorolojik yer sabit yörüngeli uydu verisini kullanarak günlük toplam GS'nin tahmini için bir model geliştirmiştir. Çalışma da Türkiye için Meteosat C3D görünür bölge görüntülerini kullanmıştır. Her bir görüntü için piksel bazlı bulutluluk indeksi oluşturmuş ve bu indekslerden günlük ortalama bulutluluk indeksini elde etmiştir. Elde edilen bu indeks ile GS arasındaki lineer ilişkiyi kullanarak Türkiye'nin günlük ve aylık GS haritalarını vermiştir. Ayrıca GS değerlerinin olmadığı geniş bölgeler için bu haritaların kullanılabilceğini belirtmiştir.

Dolar (2006) Slovenya’da GS’ni interpolasyon yöntemi ile tahmin etmiştir. Dört mevsim için 1 km yersel çözünürlüklü haritalar hazırlamıştır. Bu GS haritaları için 43 meteorolojik istasyonun 30 yıllık (1971-2000) mevsimsel ortalama değerlerini kullanmıştır. Çalışmada üç farklı yöntem kullanılmış ve en iyi sonucu residual kriging ile elde edildiği belirtilmiştir.

Robaa (2008) Mısır’da bulutluluk verisinden GS’ni hesaplamıştır. Çalışmada 1990-2005 yılları arasındaki 34 istasyona ait aylık ortalama GS ve bulutluluk verilerini kullanmıştır. Nispi GS’nin tahmini için bulut miktarına bağlı üç farklı deneysel formül türetmiştir. 30⁰ kuzey enlemini sınır kabul edip alt ve üst bölgesi için farklı iki formül vermiştir. Üçüncü denkleme ise Mısır’ın genelinde kullanmak için vermiştir.

Sanchez-Lorenzo ve ark (2008) Avrupa’nın batısı için GS’nin 1938-2004 zamanları arasındaki yersel ve zamansal değişimini incelemiştir. İncelenen tüm zaman periyodu için yıllık GS’nin doğrusal eğilimi anlamsız bulunmuş fakat GS 1950’den 1980’lerin başlarına kadar genel bir düşüş gösterirken sonraki 20 yıllık zaman diliminde iyileşme görülmüştür. Bu durum literatürde kararma ve aydınlanma (dimming and brightening) olarak bilinen durum ile uyumludur. Mevsimsel GS analizinde ilkbahar serilerinin negatif eğilimde olmasına rağmen, yıllık GS değişime benzer olduğu, ve kış serilerinde belirgin artış olduğu bildirilmiştir.

Good (2010) Birleşik Krallık (UK) için yer sabit yörüngeli uydu verisinden günlük GS’ni tahmin etmiştir. Çalışmada Meteosat uydusunun SEVIRI sensöründen SAFNWC (Satellite Application Facility on Support to Nowcasting and Very Short-Range Forecasting) birimi tarafından üretilen bulut tipi ürünü kullanılmıştır. 15 dakikada bir üretilen bu ürün 21 farklı sınıftan oluşmaktadır. 15 dakikalık görüntülerden (slot) bulut tipine göre her bir pikselin güneşlenmeye katkısı 0 ile 1 arasında değerlendirilmiş ve günlük güneşlenme indeksi hesaplanmıştır. Bu indeks ve gün uzunluğu kullanılarak günlük GS tahmin

edilmiştir. Tahmin sonuçları iki farklı yöntemle yapılan yer ölçümleri ile kıyaslanmış ve sonuçların oldukça iyi olduğu belirtilmiştir.

Matuszko (2012) Polonya da bulutluluğun GS'ne etkisini analiz etmiştir. Çalışmada GS ile bulutluluk arasındaki ilişki, 1884-2007 yılları arasındaki veriler kullanılarak kuadratik regresyon ile tanımlanmıştır. Bulutluluğun GS'ne en fazla etkisinin Haziran ve Temmuz aylarında, en az etkinin ise Aralık, Ocak, Şubat aylarında olduğu belirtilmiştir. Ayrıca çalışmada bulut tiplerinin de GS üzerine etkilerini değerlendirmiştir. Gökyüzü yüksek bulutlarla (sirus) tamamen kapalı iken bile GS'nin ölçüldüğünü, stratus bulutlarının da güneş ışınımını her zaman geçirmediğini belirtmiştir.

Shamim ve ark (2012) uydu verilerini kullanarak toplam günlük GS'nin tahmini için bir teknik geliştirmişlerdir. Çalışmada Meteosat uydusunun görünür bölge kanalının (0.6µm) verilerini kullanmışlardır. Öncelikle güneşin geometrik etkisi için ham piksel değerlerini güneş zenit açısını kullanarak normalize etmişler ve atmosferik etkinin (air mass) giderilmesi için de yine normalize işlemi uygulamışlardır. Güneş ve atmosferik etkilerin giderilmesiyle elde edilen piksel değerlerinden her görüntü için bulutluluk indeksi oluşturulmuş ve daha sonra günlük ortalama bulut indeksi hesaplanmıştır. Günlük bulut indeksini kullanarak atmosferik geçirgenliği (atmospheric transmissivity) hesaplamışlar ve bu atmosferik geçirgenlik değerlerini kullanarak ta GS'ni tahmin etmişlerdir. Bu modelin farklı coğrafik bölgelere ve değişik iklim tiplerine uygulama ihtiyacı olduğunu da belirtmişlerdir.

Bertrand ve ark (2013) Belçika'da günlük GS'ni uydu ve yer verilerinin birlikte kullanılmasıyla tahmin etmişlerdir. Çalışmada regresyon ve interpolasyon yöntemlerini kullanarak iki farklı yaklaşımla GS'ni hesaplamışlardır. MSG (Meteosat Second Generation) uydu verilerini kullanarak üç farklı yöntemle açıklık/geçirgenlik indeksini (clearness index) GS tahmininde kullanmak üzere elde etmişlerdir. Bu indeksleri her iki yöntemde ayrı ayrı ve birlikte kullanarak nispi GS ile ilişkisini vermişlerdir. Ayrıca uydudan elde edilen direkt güneş

enerjisinden hesaplanan uydu bazlı GS ile günlük GS arasındaki lineer ilişkiyi de vermişlerdir. Çalışmada en iyi tahminin uydudan elde edilen düzeltilmiş açıklık indeksinin kullanıldığı interpolasyon yönteminin verdiğini belirtmişlerdir.

Akinoglu ve Rusen (2013) global güneş ışınımını tahmin etmek için yerde ölçülen GS verisi ile uydu görüntülerinden elde edilen bulutluluk indeksinin birlikte kullanımını incelemişlerdir. Çalışmada GS verisi ve uydu verileri kullanılarak tahmin edilen günlük güneş radyasyonu modellerini vermişlerdir. Son zamanlarda kullanılan birleşik (combined) modelleri incelemişler ve klasik yöntemlerle kıyaslamasını yapmışlardır. GS ve bulutluluk indeksinin birlikte kullanıldığı modelin en iyi sonucu verdiğini belirtmişlerdir. Uydu bazlı Heliosat modelinin bazı günler hariç yüksek doğruluk verdiğini ifade etmişlerdir. Ayrıca farklı iklim tipine sahip veya ölçüm yapılan yerden uzak noktalar için Angström-Prescott tipi yöntemin yerine Heliosat metodunun kullanılmasını tavsiye etmişlerdir. Dünya çapında test edilen kuadratik modellerin de yüksek doğruluğa sahip olduğu belirtilmiş ve sadece GS verisi olduğu bir bölgede bu yöntemin kullanılmasını tavsiye etmişlerdir.

Mohandes ve Rehman (2013) Suudi Arabistan'da GS'ni makine öğrenme algoritmalarını kullanarak tahmin etmişlerdir. Çalışmada DVM ve Parçacık sürü optimizasyonu (PSO, Particle Swarm Optimization) yöntemlerini kullanmışlardır. Bu yöntemlere girdi olarak gün uzunluğu, atmosfer dışı güneş ışınımı, konum (enlem, boylam, yükseklik) ve ay parametrelerini kullanmışlardır. Yöntemlerin genellikle yaz aylarında (Temmuz, Ağustos) yüksek hata ve kış aylarında (Ocak, Şubat, Kasım ve Aralık) düşük hata verdiğini belirtmişlerdir. Ayrıca Suudi Arabistan'a benzer diğer ülkelerde de bu yöntemlerin uygulanmasıyla benzer sonuçların elde edileceğini belirtmişlerdir.

Kothe ve ark (2013) Avrupa için uydu verileriyle GS'ni hesaplamışlardır. Çalışmada günlük ve aylık GS'ni türetmek için CM SAF (Climate Monitoring Satellite Application Facility) birimi tarafından üretilen MSG uydusunun iki farklı ürünüyle değişik iki yöntem uygulamışlardır. Yöntemin birinde bulut tipi ürünü

kullanılırken diğerinde yüzeye direkt gelen güneş radyasyonunu veren ürün kullanılmıştır. Bulut tipi ürününü kullanan modelde bulut tiplerine göre 0 ile 1 arasında günlük indeks oluşturulmuş ve gün uzunluğu da kullanılarak GS tahmin edilmiştir. Diğer yöntemde ise direkt güneş radyasyonu ürünü güneş zenit açısına göre yeniden normalize edilerek tahmin için kullanılmıştır. Bu iki yöntem kıyaslandığında direk güneş ışınımını kullanan modelin daha temel olduğunu, bulut tipini kullanan modelin ise bulutlara ilişkin birkaç yaklaşıma ihtiyaç duyduğunu ve daha karmaşık olduğunu belirtmişlerdir. Tahmin sonuçları istasyon verisiyle kıyaslandığında direkt güneş ışınımını kullanan modelin daha iyi sonuç verdiği belirtilmiştir.

Kandirmaz ve Kaba (2014) günlük GS'ni Aqua ve Terra uydularındaki MODIS (Moderate Resolution Imaging Spectrometer) sensörünün verisini kullanarak tahmin etmişlerdir. Çalışmada MOD02QKM ve MYD02QKM isimli yansıtma (reflectance) ürünleri Heliosat yönteminde kullanılmıştır. Her bir görüntü için yansıtma değerlerinden bulutluluk indeksi oluşturulmuş ve bu indekslerden de günlük ortalama bulut kapalılığı elde edilmiştir. Bu bulutluluk ile GS arasındaki lineer ve kuadratik ilişkiyi gösteren denklem ve katsayılar verilmiştir.

Vivar ve ark (2014) fotovoltaik güneş pili tarafından ölçülen global güneş enerjisinden GS'ni tahmin etmişlerdir. Bu çalışmada WMO (World Meteorological Organization) tarafından kullanılan GS ölçüm yöntemlerini ve buna alternatif düşük maliyetli GS ölçümünü karşılaştırmışlardır. Güneş pilleriyle ölçülen enerji değerini kullanarak düşük maliyetli bir yöntemle GS'nin ölçülmesini incelemişlerdir. Bu yöntemin klasik ölçüm yöntemlerine göre iyi ve eksik yanlarını belirtmişlerdir.

Kandirmaz ve ark (2014) yapay sinir ağlarını kullanarak Türkiye için aylık GS'ni tahmin etmişlerdir. Çalışmada 34 adet yer istasyonunun 1980-2006 yılları arasındaki bulutluluk, gün uzunluğu ve ay verileri modellere girdi olarak kullanılmıştır. Üç farklı YSA modeli ile yapılan tahmin değerlerini kullanarak modellerin sonuçlarını kıyaslamışlardır. Kullanılan yöntemlerden GRNN'nin

(Generalized Regression Neural Network) MLP (Multi Layer Perceptron) ve RBF'e göre daha iyi sonuç verdiği ve ölçüm cihazlarının olmadığı bir nokta için GS'nin bu yöntemlerle bulanabileceği belirtilmiştir.

Rahimikhoob (2014) İran da güneş ışıının şiddeti ve terleme-buharlaşıma (evapotranspirasyona) tahmininde kullanmak için iklim verilerinden GS'ni tahmin etmiştir. Bu çalışmada GS verisini tahmin etmek için minimum ve maksimum hava sıcaklığı, bağıl nem ve atmosfer dışı güneş ışıınınını girdi parametre olarak yapay sinir ağlarında kullanmıştır. Çalışmada tahmin edilen GS'nin, güneş ışıının şiddeti ve terleme-buharlaşıma tahminine etkisini analiz etmiştir.

Zhu ve ark (2015) Çin'de bir uzaktan algılama modeliyle aylık GS'ni 100 metre yersel çözünürlükle tahmin etmişlerdir. Çalışmada arazi yapısından kaynaklanan etkileri yansıtmak için sayısal yükseklik modeli (SYM) ve atmosferik etkiler için de MODIS'in bulut ürünü (MOD06 ve MYD06) kullanılmıştır. GS'nin mevsimsel ve bölgesel değişimini analiz etmişlerdir. MODIS bulut ürünüyle yapılan tahminin doğruluğunun daha yüksek olduğunu belirtmişlerdir. GS'nin Nisan, Temmuz ve Ekim aylarında bulut etkisiyle büyük ölçüde değişim gösterdiği, fakat Ocak ayında fazla olan güneşli günlerde değişimin daha az olduğunu belirtmişlerdir. Ayrıca modelin geliştirilebileceğini ve güneş enerjisi gibi başka konulara da uygulanabileceğini ifade etmişlerdir.

Matuszko (2015) yaptığı çalışmada GS ölçüm yöntemlerinden Campbell-Stokes helyografi ile CSD3 elektronik cihazın günlük verilerini kıyaslamıştır. İki aletinde genelde benzer sonuçlar kaydettiğini fakat CSD3 cihazının, özellikle maksimum solar radyasyonun olduğu günlerde GS'ni birkaç saat fazla ölçtüğünü belirtmiştir. CSD3 cihazının solar radyasyona daha hassas olduğu belirtilmiştir. Bu gün doğumu ve gün batımına yakın saatlerde Campbell-Stokes helyografinin kayıt yapmazken CSD3 cihazının kayıt yapabileceği anlamına gelir. Ayrıca hava da kümülüs bulutlarının varlığında CSD3 cihazının Campbell-Stokes helyografına göre bir saate kadar eksik kayıt yaptığı da belirtilmiştir.

Wu ve ark (2016) Çin'de uydu tabanlı bir metod ile GS'ni tahmin etmişlerdir. Bu metod FY-2D sabit yörüngeli meteorolojik uydusundan elde edilen sınıflandırılmış saatlik bulut verisini kullanmaktadır. Yer ölçümleriyle modelin sonuçlarını test etmişler ve bu uydu verilerinin GS'ni başarılı bir şekilde tahmin etmek için kullanılabileceğini belirtmişlerdir.

Kaba ve ark (2016) Türkiye'de günlük GS'ni DVM ile tahmin etmişlerdir. Çalışmada yer istasyonlarınca ölçülen GS, bulutluluk, maksimum ve minimum sıcaklık, rüzgar hızı ve nem ile gün uzunluğu verilerini kullanmışlardır. DVM'nde lineer, polinom ve radyal bazlı olmak üzere üç farklı çekirdek fonksiyonu ile tahmin yapılmış ve bu fonksiyonlardan radyal bazlı çekirdek fonksiyonunun en iyi sonucu ürettiği belirtilmiştir. Ayrıca nem verisi kullanılan modellerinde diğerlerine göre daha iyi sonuç verdiği belirtilmiştir.

Founda ve ark (2017) Yunanistan'da uzun dönem güneşlenme süresi ve bulutluluk gözlemlerinden kararın ve aydınlanmayı (dimming and brightening) çalışmıştır. Çalışmada 15 yer istasyonunun verileri kullanılarak GS ve bulutluluğun yersel ve zamansal değişimi tespit edilmiştir 1980'lerin ortalarına kadar GS'ndeki azalışın batı Yunanistan'da daha belirgin olmakla beraber tüm Yunanistan'da gerçekleştiği bildirilmiştir. Yunanistan'ın güneydoğusu için 1980'lerin ortalarından bu yana GS'nin arttığı fakat bulutluluğun bu artışa eşlik etmediğini belirtmiştir. Bunun ise aerosolden kaynaklanabileceğini tahmin etmiştir.

3. MATERYAL VE METOD

3.1. Materyal

Bu çalışmada Türkiye'nin günlük ve aylık GS'ni tahmin etmek amacıyla farklı yöntemlerle elde edilmiş veriler ile çalışılmıştır. Bu veriler 2013 ile 2015 yılları arasındaki üç yıllık zaman dilimini ve 35-43 kuzey enlemleri ile 25-46 doğu boylamları arasını kapsamaktadır. Çalışmada kullanılan verileri başlıca dört grupta toplamak mümkündür. Bunlar aşağıda şekilde sıralanmıştır.

- Ø Yer verisi
 - § Güneşlenme süresi
- Ø Coğrafi veriler
 - § Zaman (Yıl, Ay, Gün)
 - § Konum (Enlem, Boylam, Yükseklik)
 - § Julien günü
 - § Deklinasyon açısı
 - § Güneş saat açısı
 - § Gün uzunluğu
 - § Atmosfer dışı güneş ışınımı
- Ø Sabit yörüngeli uydu verileri
 - § 7 adet SEVIRI termal kanal verileri
- Ø Kutupsal yörüngeli uydu verileri
 - § 9 adet VIIRS solar kanal verileri

Yer verisi olarak MGM tarafından gözlem istasyonlarında ölçülen GS kullanılmıştır. Coğrafi veriler ise zaman (yıl, ay, gün), konum (enlem, boylam, yükseklik), julien günü, deklinasyon açısı, güneş saat açısı, gün uzunluğu ve atmosfer dışı güneş ışınımından oluşmaktadır. Sabit yörüngeli uydu verileri için, Meteosat uydusundaki SEVIRI sensörüne ait yedi adet termal kanal verileri

kullanılmıştır. Kutupsal yörüngeli uydu verileri ise Suomi-NPP uydusundaki VIIRS sensörüne ait dokuz adet solar kanal verisinden oluşmaktadır. İki farklı uydu verilerinin kullanımı ile spektral anlamda birbirini tamamlayacak bilgi elde edilmiş ve kanal çeşitliliği sağlanmıştır. Bu verilerin elde edilmesinde, ön işlemden geçirilmesinde, işlenmesinde ve analiz edilmesinde aşağıdaki yazılım ve donanımlar kullanılmıştır;

Donanımlar:

- Ø 1 adet Intel i5 işlemcili, 10 GB RAM ve 1 TB Hard disk sürücülü Linux (Fedora) işletim sistemli kişisel bilgisayar.
- Ø 1 adet Intel i5 işlemcili, 8 GB RAM ve 1 TB Hard disk sürücülü Windows işletim sistemli dizüstü bilgisayar.
- Ø 1 adet 1.5 TB harici hard disk
- Ø 1 adet 1 TB harici hard disk.

Yazılımlar:

- Ø FileZilla FTP Client
- Ø HDF View
- Ø Python Programlama Dili (Sürüm 3.4)
- Ø CSPP_IMAPP_POLAR2GRID_V2.0
- Ø Microsoft Office Excel 2010

FileZilla FTP Client Windows, Linux ve Mac OS X işletim sistemlerinde çalışan özgür bir FTP (File Transfer Protocol - Dosya Aktarım Protokolü) istemcisidir. FileZilla FTP Client uydu görüntülerinin indirilmesinde kullanılan yazılımdır. HDF (Hierarchical Data Format – Hiyerarşik Veri Formatı) View, hdf uzantılı dosyaların okunmasında ve yazılmasında kullanılan ücretsiz elde edilebilen

bir programdır. Python nesne yönelimli, yorumlanabilir, modüler, etkileşimli ve platformdan bağımsız üst düzey programlama dilidir. Python ile sistem programlama, ağ programlama, uygulama ve veri tabanı programlama gibi birçok alanda yazılım geliştirilebilmektedir. Özgür programlama dili olan python görüntü işleme ve yapay öğrenme konuları başta olmak üzere çalışmanın her aşamasında sunulan kütüphaneler ile birlikte kullanılmıştır. Python ile kurulu gelmeyen ve sonradan kurulan başlıca python kütüphanelerinin bir listesi aşağıda verilmiştir. POLAR2GRID yazılımı yer gözlem uydularındaki cihazlardan swath veri çıkarımı, grid verinin yeniden haritalanması (remapping) ve grid veriyi yeni bir dosya formatında yazmak için kullanılan bir araç setidir. POLAR2GRID programı SSEC'deki (Space Science And Engineering Center) bilim adamları ve yazılım geliştiriciler tarafından Python dili kullanılarak yazılmıştır. CSPP (Community Satellite Processing Package) projesinin bir kısmı olarak görüntü işleme için dağıtılmaktadır. POLAR2GRID yazılımı VIIRS sensörüne ait verilerin işlenmesi için kullanılan özgür yazılımdır ve çalışmanın bu döneminde sadece Linux sürümlerinde çalışmaktadır.

Çalışmada kullanılan Python kütüphaneleri:

- Numpy-1.11.0
- Scikit-learn-0.17.1
- Matplotlib-1.5.2
- H5py-2.6.0
- GDAL-2.0.2
- Basemap-1.0.8
- Ephem-3.7.6

3.1.1. Güneşlenme Süresi

Dünya Meteoroloji Örgütü'nün (WMO, 2010) tanımına göre, GS verilen bir periyod boyunca birim alana ulaşan direkt güneş radyasyonunun 120 W/m^2 eşik değerine eşit veya geçtiği sürelerin toplamıdır. GS için kullanılan birim zamandır. Kullanılan birimler saat, gün, ay, mevsim veya yıllık olarak verilebilmektedir. Yapılan çalışmalara bağlı olmakla birlikte daha çok saat/gün ve saat/ay birimleri kullanılmaktadır.

Ülkemizde GS, MGM tarafından kurulup işletilen rasat parklarında ölçülmektedir. Rasat parkı, atmosfer olaylarına açık, bu olayları engelleyici faktörlerin olmadığı, içinde çeşitli meteorolojik aletlerin bulunduğu doğal şartları temsil eden düzenlenmiş yerlerdir. Bu yerlerde sıcaklık, basınç, nem, yağış, güneşlenme, rüzgâr, buharlaşma gibi hava olaylarını meteorolojik aletlerle ölçerek kayıtlar tutulur. Tutulan bu kayıtlara rasat denir. Meteorolojide klima rasatları, sinoptik rasatları gibi rasatlar yapılmaktadır. Yapılan bu rasatlar içinde klimatolojik rasatlar dünyanın, kıtaların, ülkelerin, ülkeler içindeki bölgelerin iklim özellikleri ile daha dar yörelerin, çevrelerin ve mahallelerin değişik iklim durumlarını incelemek, iklim araştırmaları ve projeleri için gerekli bilgileri elde etmek amacıyla yapılan rasatlardır. Bu rasatlar ilgili devletler ve kuruluşlar tarafından düzenlenmiştir. Bu düzenlemelerde amaç; tüm ülkelerde, meteoroloji istasyonlarında yapılan ölçümlerde günlük ortalama kıymetleri elde edebilecek şekilde, yerel saatlerde rasatların yapılmasıdır. Türkiye'de ve daha birçok ülkede 07^{00} - 14^{00} - 21^{00} yerel saatleri seçilmiştir. Bu rasatların en büyük özelliği aynı güneş durumunda yapılmış olmalarıdır. Rasat parkları ülkemizde büyük ve küçük klima şeklinde kurulmuştur. Ancak zamanla büyük klima istasyonlarına çevrilmiş küçük klima rasat parkları giderek azalmaktadır. Aşağıda büyük ve küçük klimalarda ölçülen meteorolojik parametreler verilmiştir (Yalçın ve ark, 2005; Erdi, 2015).

Büyük klima istasyonlarında yapılan rasatlar, saatleri ve kullanılan aletler:

1. Basınç rasatları (07⁰⁰-14⁰⁰-21⁰⁰, barometre-barograf)
2. Sıcaklık rasatları (kuru termometre 07⁰⁰-14⁰⁰-21⁰⁰, maksimum - minimum termometre 07⁰⁰-21⁰⁰, termograf – 24 saat)
3. Nem rasatları (psikrometre 07⁰⁰-14⁰⁰-21⁰⁰, higrograf 24 saat)
4. Bulutluluk rasatları (07⁰⁰-14⁰⁰-21⁰⁰)
5. Görüş uzaklığı rasatları (07⁰⁰-14⁰⁰-21⁰⁰)
6. Güneşlenme rasatları (güneşin doğuşundan, batışına kadar- helyograf)
7. Radyasyon rasatları (güneşin doğuşundan, batışına kadar– aktinograf)
8. Buharlaşma rasatları (piche evaporimetresi 07⁰⁰-14⁰⁰-21⁰⁰, buharlaşma havuzu 07⁰⁰)
9. Rüzgâr rasatları (sabit anamometre 07⁰⁰-14⁰⁰-21⁰⁰, anemograf ile 24 saat)
10. Yağış ve diğer hidrometeorlar (rasatçı tarafından 24 saat takip edilir, plüviyometre'den 07⁰⁰-14⁰⁰-21⁰⁰, plüviyograf 24 saat)
11. Kar rasatları (yükseklik; kar eşeli, kar bastonu, kar tahtası, cetvel 07⁰⁰, yoğunluk; kar yoğunluğu aleti 07⁰⁰)
12. Toprak sıcaklıkları (5-10-20 -50 cm 07⁰⁰-14⁰⁰-21⁰⁰, 100 cm 14⁰⁰)
13. Meteorolojik olaylar (Rasatçı tarafından gözlemlenir)
14. Fenolojik Rasatlar (Rasatçı tarafından her ay takip edilir)
15. Açık Siper Rasatları

Küçük klima istasyonlarında yapılan rasatlar:

1. Sıcaklık
2. Nem rasatları
3. Yağış ve diğer hidrometeorlar
4. Rüzgâr rasatları
5. Bulutluluk rasatları

6. Kar rasatları (Yalçın ve ark, 2005)

GS uzun yıllardır meteorolojik istasyonlarda noktasal olarak Campbell-Stokes helyografı ile ölçülmektedir. Bu aleti ilk olarak 1858 de Campbell icat etmiş ve 1879'da Stokes'un katkısıyla Campbell-Stokes helyografı olarak adlandırılmış ve o zamandan beri bu cihaz otomatik olmayan istasyonlarda kullanılmaktadır (METOFFİCE). Şekil 3.1'de görüldüğü gibi cihaz destekle sabitlenmiş renksiz cam bir küre ve bu kürenin altında içine ölçekli kâğıt yerleştirilen bir oyuktan oluşmaktadır. Küre üzerine düşen güneş ışığını toplar ve alttaki ölçekli kâğıt yanmasını sağlar. Gözlemci gün sonunda kâğıt üzerindeki yanık izlerini değerlendirerek GS'ni belirler. Diyagram üzerindeki yanığın genişliği ve derinliği güneş ışınlarının parlaklık durumuna bağlıdır. Bu nedenle kullanılan kâğıtlar kışlık, yazlık ve baharlık olmak üzere mevsimlere özel değişim göstermektedir.



Şekil 3.1. Campbell-Stokes helyografı (BOM)

Şekil 3.2'de helyografıta kullanılan diyagramlar (ölçekli kağıtlar) verilmiştir. Her gün güneş battıktan sonra helyograf diyagramları değiştirilir.

Saatlik GS'ni elde etmek için diyagramlar üzerindeki yanık izleri değerlendirilir. Değerlendirmede küçük yanıklar da dikkate alınmalıdır. Doğru bir ölçüm için bir saatin 10 eşit parçaya bölümünü temsil eden bir plastik şablondan yararlanılır. Bu şablonun kullanılmasıyla GS 0.1 saat hassasiyetle ölçülür (Yalçın ve ark, 2005).



Şekil 3.2. Campbell-Stokes helyograf diyagramları (PIERCECOLLEGE)

Heliograf ölçümleri kararlı fakat önemli ölçüde GS'ni fazla ölçmektedir. Bunun nedeni hızlı değişen bulut hareketleridir. Güneş bulutlar tarafından kapatıldığında bile ölçekli kâğıt yanmaya devam etmektedir. Bu ölçüm yöntemi bunun dışında da aletin konumu, kalibrasyonu ve kullanıcı gibi etkenlerden dolayı hata içerebilmektedir. Son zamanlarda ise tam otomatik istasyonlara geçilmesiyle yeni GS cihazı (Sunshine Duration Meter, CSD 1) kullanılmaya başlanmıştır. Şekil 3.3'te CSD 1 cihazının görüntüsü verilmiştir. Bu cihaz üç sensörden oluşmaktadır. Birinci sensör gün ışığını tespit edince bunu elektriğe dönüştürür ve global güneş enerjisi üretilen bu voltajdan hesaplanır. Arkadaki iki sensör yaygın (diffuse) güneş enerjisini ölçmek için kullanılır. Bu iki sensörün ölçümlerinden değeri küçük olan

kullanılır. Bu deęer yaklaşık olarak yaygın güneş enerjisinin üçte biridir ve bunun kalibrasyonu yapılarak birinci sensörde ölçülen global güneş enerjisi deęerinden çıkarılınca aradaki bu fark direkt güneş enerjisini verir. Eđer direkt güneş enerjisi deęeri 120 W/m^2 eşik deęerine eşit ya da büyükse GS'nin varlığı tanımlar.




Şekil 3.3. CSD 1 dijital güneşlenme süresi ölçer (METOFFİCE)

3.1.2. Coğrafik Veriler

Çalışmada kullanılan bir diğer veri grubu coğrafik verilerdir. Bu zaman, konum, julien günü, deklinasyon açısı, güneş saat açısı, gün uzunluğu ve atmosfer dışı güneş enerjisinden oluşmaktadır. Julien gün sayısı (j) yılın günlerine verilen sayısal değerleri ifade etmektedir. Bir örnekle açıklayacak olursak yılın birinci günü yani 1 Ocak'ta j'nin 1 olduğu, 1 Şubat'ta j'nin 32 ve yılın son gününde 365 veya 366 olduğu anlamına gelir. Deklinasyon açısı (δ) ise güneş ışınlarının ekvator düzlemi ile yaptığı açıdır. -23.45 ile 23.45 derece arasında değişir ve 21 Haziranda en büyük değerini alırken, 21 Aralıkta en küçük değerini alır. 21 Mart ve 21 Eylül ekinokslarında (gün dönümlerinde) sıfır olur. Şekil 3.4'de δ ve onun yıllık değişimi verilmiştir. δ j'ye bağlı olup eşitlik 3.1 ile hesaplanır (Allen ve ark, 1998).

$$\delta = 0.409 * \sin[(2 * \pi * j/365) - 1.39] \quad (3.1)$$



Şekil 3.4. Deklinasyon açısı ve yıllık değişimi (POWERFROMTHESUN)

Güneş saat açısı (ω_s) güneş ışınlarının bulunduğu boylam ile gözlemcinin bulunduğu boylam arasındaki açıdır. Her bir saatte bir 15 derece değişir. Öğle saat 12 de sıfır, öğleden önce negatif ve öğleden sonra pozitif değerlidir. Örneğin saat 10 iken $\omega_s = -30^0$ ve saat 15'de $\omega_s = +45^0$ 'dir. Bu çalışmada saat açısının gün batımındaki değerleri kullanılmıştır. Φ enlem açısı ve δ deklinasyon açısı olmak üzere eşitlik 3.2 ile hesaplanır (Allen ve ark, 1998).

$$\omega_s = \cos^{-1}(-\tan \Phi * \tan \delta) \quad (3.2)$$

Güneşin doğuş saati ile batış saati arasındaki zaman dilimi gün uzunluğu veya maksimum güneşlenme süresi olarak tanımlanır. Gerçek güneşlenme süresi, hiç bir atmosferik etki olmadığı durumda veya atmosferin üzerinde gün uzunluğuna eşit olur. Gün uzunluğu güneşlenme süresinin üst limitini belirlemektedir. Maksimum güneşlenme süresi enlem açısına ve julien gün sayısına bağlıdır. Çalışmada kullanılan girdilerden biri olan gün uzunluğu S_0 olmak üzere, istenen bir coğrafi koordinat ve zaman için eşitlik 3.3 ile hesaplanır (Allen ve ark, 1998).

$$S_0 = 24 * \omega_s / \pi \quad (3.3)$$

Çalışmada kullanılan coğrafi verilerden bir diğeri atmosfer dışı güneş ışımasını (G) eşitlik 3.4 ile hesaplanır. G atmosfer dışı günlük ışıma (MJ/m²/gün), G_{sc} güneş sabiti ve $G_{sc} = 0.0820$ MJ/ m²/dakika değerindedir. Denklemden d ters bağımlı Dünya-Güneş uzaklığı olup eşitlik 3.5 ile hesaplanır (Allen ve ark, 1998).

$$G = \left(\frac{24*60}{\pi} \right) * G_{sc} * d * [\omega_s \sin \varphi \sin \delta + \cos \varphi \cos \delta \sin \omega_s] \quad (3.4)$$

$$d = 1 + 0.033 \cos(2\pi j / 365) \quad (3.5)$$


3.1.3. Sabit Yörüngeli (Geostationary) Meteosat Uyduları

Yer sabit yörüngeli uydular, ekvator üzerinden yaklaşık 36000 km yükseklikteki bir yörüngede konumlandırılmaktadır. Bu uydular Dünya ile aynı açısal hıza sahip olduğundan her zaman yer yüzeyinin aynı bölgesini görmektedir. Bu tip yörüngeye sahip uydular daha çok meteorolojik uygulamalar için kullanılmaktadır. Sabit yörüngeli uydular kendi eksenini etrafındaki dönüşleri esnasında üzerlerindeki pasif algılayıcı cihazlarla yapılan kayıtları (count değerlerini) yer istasyonlarına aktarırlar. Veriler yer istasyonlarında işlenerek ana bilgisayar merkezine gönderilir ve orada işlenen veriler tekrar yer istasyonuna gönderilerek uydu aracılığı ile kullanıcılara dağıtılır (MGM).

Uydu tarafından yer istasyonuna gönderilen ham veriler, yer istasyonundan yüksek iletişim kapasitesine sahip hatla ana bilgisayar merkezine gönderilir. Bu merkeze gelen ham veri üzerinde navigasyon düzeltmeleri yapılır. Navigasyon hesaplarının yapılmasının nedeni, uyduların yörüngelerini değiştirmelerinde sabit kalmayıp, uzaydaki dışsal kuvvetlerin etkisi altında sürekli olarak sürüklenmeleri ve bu yüzden dünya üzerindeki aynı bölgeyi farklı yörüngelerden görmelerinden doğan hataları gidermektir. Navigasyon düzeltmeleri ile uydu tarafından alınan ham veriler sabit bir referans yörüngesine indirgenir. Bu sebeple kullanıcı için uydunun aldığı veriler sabit bir yörüngeden alınıyormuş gibi görünür. Üzerinde düzenlemeler yapılan ham veriler tekrar yer istasyonuna gönderilerek uydu aracılığı ile kullanıcı istasyonlarına gönderilir (MGM).

Yer sabit yörüngeli Meteosat uydu sistemi ilk olarak 1970'lerin başlangıcında tasarlanmış ve ilk model 1977'de fırlatılmıştır. Aynı tasarımın 2003 yılının sonuna kadar kullanılacağı öngörülmüştür. Beklenen 26 yıllık operasyonel servis kullanımı ilk zamandaki gelişim çabalarını haklı çıkarmıştır. Meteosat-3'ten sonra nispeten küçük sayılabilecek tasarım değişiklikleri yapılmıştır. Uydunun boyutları 2.1 m çapında olup, 3.195 m uzunluğundadır. Yörüngesindeki başlangıç kütlesi 282 kg'dır. Bu dara ağırlığına ilaveten, mevcut durumunu koruması için hidrazin propellant taşımaktadır, bunun yaptığı ilave ağırlık ise yaşam süresinin

başlangıcında yaklaşık 40 kg'dır. Uydu yörüngesinde ana eksenini etrafında 100 rpm hızıyla dönmektedir, bu dönüş hızı ise dünyanın kuzey-güney eksenine neredeyse paralel sayılır. Meteosat temel olarak tepesinde davul şekilli bölüm bulunan (çapı 1.3 m) ana silindirik bir gövdeden ve ilave olarak konulmuş eş merkezli iki silindirden meydana gelmiştir. Ana gövde, uydunun radyometreyi de kapsayan bütün alt sistemlerinin çoğunu barındırmaktadır. Yüzeyi, elektriksel güç sağlayan güneş hücreleriyle kaplanmış altı adet panelden meydana gelmektedir. Şekil 3.5'te yer sabit yörüngeli Meteosat uydularının şeması verilmiştir (MGM).



Şekil 3.5. Yer sabit yörüngeli Meteosat uydusunun şeması (MGM)

S/UHF platformunun üzerine monte edilen daha küçük davul şekilli bölümün silindirik yüzeyi, radyatif dipol anten elementleri sırasıyla kaplanmıştır. Bu silindirik gövde içindeki elektronik aksamlar, uydunun dönüş sırasında algılama yapması için, bireysel elementleri sırasıyla aktive eder. Bu sistem, görevi S

bandındaki bütün gönderimlerin dünyayı işaret etmesi olan elektronik-despun anteni oluşturur. Ana silindirik gövdenin tepesine monte edilmiş olan iki silindir S-band ve düşük UHF bölümlerini içermektedir. Yoğun iticiyi içeren apogee boost motoru, başlangıçta fırlatma öncesinde uydunun tabanına yerleştirilmiştir. Bu, uydunun fırlatma sonrasında yüksek derecede eliptik olan yörüngesinden, arzulanan dairesel ekvatorial yörüngesine oturtmakta kullanılır. Bu patlamayı takiben apogee boost motoru uydu gövdesinden ayrılır, böylece geride infrared radyometre detektörlerini soğutan radyatif soğutucu için açık bir manzara bırakır (MGM).

Türkiye'nin kurucu üyelerinden biri olduğu EUMETSAT (European Organisation for the Exploitation of Meteorological Satellites), Avrupa için uyduların tesisi, bakımı, işletimi, geliştirilmesi ile güvenilir veri, görüntü ve ürün dağıtımını yapmaktadır. EUMETSAT, kullanıcılarının operasyonel meteorolojik uydu ihtiyaçlarını karşılamak üzere hâlihazırda sabit yörüngeli Meteosat uydularını ve kutupsal yörüngeli Metop uydularını işletmektedir. EUMETSAT'ın ilk sistemi ESA (Avrupa Uzay Ajansı) tarafından geliştirilmiş olan sabit yörüngeli Meteosat uydularıdır. Bu seride Meteosat 1, 2, 3, 4, 5 ve 6 ESA tarafından MOP (Meteosat Operational Programme) programı çerçevesinde uzaya fırlatılmış olup, Meteosat-7 ise 1997 yılında MTP (Meteosat Transition Programme) programı çerçevesinde uzaya fırlatılmıştır. 2002 yılında EUMETSAT'ın ikinci nesil uydusu Meteosat-8'i, 2005 yılında Meteosat-9'un ve 2012 yılında Meteosat-10'un fırlatılması takip etmiş ve bu program çerçevesinde 2018 yılına kadar bir tane daha MSG uydusu fırlatılması planlanmıştır. Halihazırda kullanılmakta olan üç adet MSG uydularına ait bilgiler Çizelge 3.1'de verilmiştir (Erdi, 2015).

Meteosat-8 ile başlayan Meteosat İkinci Nesil (MSG) uyduları, oldukça etkili iki cihaz taşımaktadır. İlk seri Meteosat uydularında yer alan cihazın gelişmiş bir versiyonu olan Dönen Gelişmiş Görünür ve Kızılötesi Görüntüleyici (SEVIRI) görüntü ve verileri sağladığından MSG için çekirdek görevini üstlenir. Buna ek olarak, MSG çok gelişmiş deneysel bir cihaz olan Sabit Yörüngeli Dünya

Radyasyon Bütçesi (GERB) cihazını da taşımaktadır. İkinci cihaz olan GERB sabit yörüngeli uydular için deneysel bir görev olarak iklim çalışmaları amacıyla eklenmiştir. Hem SEVIRI hem de GERB gelişmiş cihazlardır. SEVIRI, gelişmiş mekânsal, zamansal ve spektral çözünürlüğüyle öncülünden on kat daha fazla veri sağlamaktadır ve 4 kat daha fazla görüntüleme kanalına sahiptir (MGM).

Çizelge 3.1. Meteosat ikinci nesil uyduları

Uydu	Fırlatma Tarihi ve Uydu Ömrü	Pozisyon	Sağladığı Hizmet
Meteosat-10 (MSG-3)	05/07/2012 - Normal yakıt ömrü 2022 yılına kadar.	0°	Asıl Tarama Hizmeti (15')
Meteosat-9 (MSG-2)	22/12/2005 - Yakıt ömrünün 2021 yılına kadar uzaması bekleniyor.	9.5° Doğu	Hızlı Tarama Hizmeti (5')
Meteosat-8 (MSG-1)	28/08/2002 - Yakıt ömrünün 2019 yılına kadar uzaması bekleniyor.	3.5° Doğu	Hızlı Tarama Hizmeti (5')

MSG'nin iletişim ile ilgili bazı görevleri olsa da öncelikli görevi Dünya'yı görüntülemektir. Bu iş için iki özel cihaz kullanılır. Ana cihaz (SEVIRI), 12 spektral kanalda, 15 dakikalık aralıklarla, gece ve gündüz boyunca Dünya'yı gözlemlemektedir. Cihaz ilk 11 kanaldan uydu alt noktasında 3 km x 3 km çözünürlükte tam disk görüntü almaktadır. Cihazın 12. kanalının (HRV) uydu alt noktası çözünürlüğü 1 km x 1 km. olup, spektral olarak da geniş bir aralıktan (0.4-1.1 μm) veri almaktadır. Cihaz 51 cm çapında bir aynaya ve 85 ya da 95 $^{\circ}\text{K}$ sıcaklığında ayarlanmış pasif soğutulan kızılötesi detektörlere sahiptir. Görüntüler uydunun dakikada 100 devir dönmesinden faydalanan doğudan batıya tarama ve her tarama çizgisinden sonra teleskop aynasının güneyden kuzeye bir adım ilerlemesiyle elde edilir. İlk 11 kanalın tümünün 3 detektörü vardır ve böylece 1250 tarama çizgisi, 3750 görüntü çizgisi oluşturmuş olur. HRV kanalı doğu-batı

diskinin yarısını tararken, 9 detektör kullanması sayesinde 1km çözünürlükte görüntü elde edilir. Tam disk görüntülerin elde edildiği tekrar döngüsü 12 dakikalık bir periyoda sahiptir. Bunun ardından; kızılötesi kanalların kalibrasyonu ve tarama aynasının başlangıç konumuna dönmesi için geçen süreyle birlikte 15 dakikaya ulaşan döngü süresinde SEVIRI cihazı toplam 2.4 Gigabit veri üretir. Çizelge 3.2’de SEVIRI cihazının kanal bilgileri verilmiştir (MGM).

Çizelge 3.2. SEVIRI algılayıcısının bandları

Kanal Numarası	SEVIRI Kanal isimleri	Merkez Dalga Boyu (μm)	Öncelikli Uygulama Alanı
1	VIS0.6	0.63	Yeryüzü, bulutlar, rüzgar vektörleri
2	VIS0.8	0.81	Yeryüzü, bulutlar, rüzgar vektörleri
3	NIR1.6	1.64	Yeryüzü, bulut safhası
4	IR3.9	3.90	Yeryüzü, bulutlar, rüzgar vektörleri
5	WV6.2	6.25	Su buharı, yüksek bulutlar, atmosferik kararsızlık
6	WV7.3	7.35	Su buharı, atmosferik kararsızlık
7	IR8.7	8.70	Yeryüzü, bulutlar, atmosferik kararsızlık
8	IR9.7	9.66	Ozon gazı
9	IR10.8	10.80	Yeryüzü, bulutlar, rüzgar vektörleri, kararsızlık
10	IR12.0	12.00	Yeryüzü, bulutlar, atmosferik kararsızlık
11	IR13.4	13.40	Sirrus bulut yüksekliği, atmosferik kararsızlık
12	HRV	0.75	Yeryüzü ve bulutlar

SEVIRI cihazı solar, görünür ya da kısa dalga olarak adlandırılan dört kanal ile termal ya da kızılötesi olarak adlandırılan sekiz kanal olmak üzere toplam 12 kanalda kayıt yapmaktadır. VIS 0.6 kanalı (kanal 1), tayfın görünür kısmında 0.6µm merkezli dar bir spektral pencerede yansıyan solar radyasyona duyarlıdır. Dört SEVIRI solar kanalı olan VIS 0.6, VIS 0.8 (kanal 2), NIR 1.6 (kanal 3) ve HRV (kanal 12) benzer bir şekilde yansıyan solar radyasyona duyarlıdır. IR 3.9 kanalı (kanal 4) özel bir durumu olan kanaldır. Kanal 3.9 µm merkezli radyasyona duyarlıdır ve bu, iki rol üstlenmesi, yani gündüz ve gece yayılan termal radyasyona, aynı zamanda gündüz yansıyan solar radyasyona duyarlı olması demektir. VIS 0.6 bulutların, VIS 0.8 kara özelliklerinin ve bitki örtüsünün, NIR 1.6 buzun ve karın, NIR 3.9 ise alçak bulutların ve sisin tespitinde en iyi sonucu verir. Bu kanalların tümü bulut, bitki örtüsü, sis ve diğer özelliklerin kesin dağılımlarını veren niceliksel ürünlerde kullanılmaktadır. Kızılötesi kanalları kara, okyanus yüzeyleri ve bulutlardan yayılan termal radyasyona duyarlı olup sıcaklıklarını gösterir. IR 8.7 kanalı (kanal 7) 8.7 µm merkezli pencere kanalındaki termal kızılötesi radyasyona duyarlıdır. IR 10.8 kanalı (kanal 9) 10.8 µm merkezli pencere kanalındaki bulutları ve yüzeyleri gösteren kanaldır. WV 6.2 kanalı (kanal 5) 6.2 µm merkezli pencere kanalındaki troposferin üst kısımlarında bulunan su buharı tarafından yayılan radyasyona duyarlıdır. Bu kanal görüntülenen alanın yüksek seviye bulut içermeyen kısımlarında, 5-8 km yükseklikte yer alan girdap şeklindeki nemi gösterir. HRV kanalı yüksek çözünürlüklü (1km) görünür kanaldır. Bu kanal yüksek çözünürlüklü görüntüler sağlamanın yanında diğer kanallara ait verilerin daha gelişmiş olarak işlenmesine izin verir. Görüntülenen bölgenin daha düşük çözünürlüklü kanallarda karşılık gelen ilgili pikseldeki bulut varlığını kontrol etmek için kullanılabilir ve daha gelişmiş bulut tespitine ve bazı ürünler için SEVIRI verisinin piksel-altı düzeyde işlenmesine imkân tanır. Aşağıda SEVIRI kanal verilerinden elde edilen Nowcasting (kısa vadeli hava tahmin) ürünlerinin listesi verilmiştir (MGM).

1. Cloud Mask (CMA) – Bulut Maskesi
2. Cloud Type (CT) – Bulut Tipi
3. Cloud Top Temperature and Height (CTTH) – Bulut Tepe Sıcaklığı ve Yüksekliği
4. Precipitating Clouds (PC) – Yağış Bulutları
5. Convection Rainfall Rate (CRR) – Konvektif Yağmur Yağış Oranı
6. Rapid Developing Thunderstorms (RDT) – Hızlı Gelişen Gök gürültülü Sağanak Yağış
7. Total Precipitable Water (TPW) – Toplam Yağışabilir Su
8. Layer Precipitable Water (LPW) – Tabaka Yağışabilir Su
9. Stability Analysis Imagery (SAI) – Kararlılık Analizi Görüntüleme
10. Air Mass Analysis (AMA) – Hava Kütleli Analizi
11. Automatic Satellite Image Interpretation (ASII) – Otomatik Uydu Görüntüsü Yorumlama
12. High Resolution Winds (HRW) – Yüksek Çözünürlüklü Rüzgâr

3.1.3.1. SEVIRI Level 1.5 Verisi

SEVIRI Level 1.5 verisi, uydu ham verisinden (Level 1.0) üretilen MSG'nin başlıca ürünlerinden birini oluşturur. Level 1.5 verisi istenmeyen tüm radyometrik ve geometrik etkilerin düzeltildiği, standartlaşmış bir projeksiyon kullanılarak konumlandırıldığı ve kalibrasyon ile radyans lineerleştirilmesinin yapıldığı bir görüntüdür. Bu veri meteorolojik ürün üretmek ve daha fazla meteorolojik işlem için temel veridir.

Level 1.0 ham verisinden Level 1.5 verisi türetilirken uygulanan radyometrik işlem başlıca dört adımdan oluşur; lineerleştirme, radyansa dönüştürme, kalibrasyon ve ölçeklendirme (scaling). Lineerleştirme, ölçümlerdeki lineer olmayan etkilerin giderilmesidir. İkinci adım piksellerin sayı değerlerinin radyansa dönüştürülmesidir. Kalibrasyon aşaması ilk tahmin edilen radyansın düzeltilmesidir. Son adım olan ölçeklendirme ise, veriyi 10-bitlik bir formatta

hazırlamak için lineer bir işlem ile radyans değerlerinin 0 – 1023 aralığına ölçekleme işlemidir.

SEVIRI Level 1.5 verisinden reflektans ya da parlaklık sıcaklığı değerlerini üretmek için, Level 1.5 verisinin sayı (count) olan piksel değerleri eşitlik 3.6 ile radyans bilgisine dönüştürülür.

$$L^{15} = \mathbf{g} * \mathbf{C} + \mathbf{b} \quad (3.6)$$

bu eşitlikte L^{15} , $\text{mWm}^{-2}\text{sr}^{-1}(\text{cm}^{-1})^{-1}$ biriminde olup, Level 1.5 ürününün radyans değerini, \mathbf{C} pikselin sayısal değerini ve \mathbf{g} ile \mathbf{b} sabitleri ifade etmektedir. Her bir uydu ve kanal için \mathbf{g} ve \mathbf{b} değerleri farklıdır. Reflektans ρ^{15} olmak üzere SEVIRI algılayıcısının solar kanallarına ait görüntüdeki herhangi bir piksel için eşitlik 3.7 kullanılarak hesaplanır.

$$\rho^{15} = (100 * L^{15} * D^2) / (c_i * \cos \theta) \quad (3.7)$$

$$D = 1 - 0.0167 * \cos[2 * \pi * (J - 3) / 365] \quad (3.8)$$

eşitlik 3.7'de D dünya-güneş arası uzaklık olup j 'ye (julien gününe) bağlı olarak eşitlik 3.8 ile hesaplanır. c_i solar kanallar için sabit olup i . kanalın (1, 2, 3, 12) ekinoksta atmosfer dışı güneş akısı ve θ güneş zenit açısıdır. Termal kanallar için parlaklık sıcaklığı T^{15} olmak üzere eşitlik 3.9 ile hesaplanır.

$$T^{15} = \frac{c_2 \vartheta}{\ln \left[1 + \vartheta^3 \frac{c_1}{L^{15}} \right]} \quad (3.9)$$

bu eşitlikte $\vartheta = \frac{10^4}{\lambda_0}$ olmak üzere $1/\text{cm}^{-1}$ biriminde dalga sayısı ve λ_0 kanalın merkezi dalga boyudur. $c_1 = 1.19104 * 10^{-5} \text{ mWm}^{-2}\text{sr}^{-1}(\text{cm}^{-1})^{-4}$ ve $c_2 = 1.43877$

$^0\text{K}(\text{cm}^{-1})^{-1}$ sabitlerdir. L_{θ} hedefin spektral radyansı olmak üzere, L^{15} terimine efektif radyans da denir ve eşitlik 3.10 ile hesaplanır (EUMETSAT, 2013).

$$L^{15} = \frac{\int L_{\theta} r_{\theta} d\theta}{\int r_{\theta} d\theta} \quad (3.10)$$

3.1.4. Kutupsal (Polar) Yörüngeli Suomi-NPP Uydusu

Yer yüzeyinden yüksekliği 700-800 kilometre civarında olan ve dünyanın kutupları arasında geçişler yaparak yeryüzünün her bölgesine ait görüntü üreten uydulara kutupsal yörüngeli uydular denir. Bu uydular yörüngelerinden dolayı yersel ve spektral çözünürlüğü ile kayıt yaptıkları bölge bakımından sabit yörüngeli uydulara göre avantajlı durumdadır. Bu uydular güneş eş zamanlı bir yörüngede işletilir ve ekvatoru her gün aynı yerel güneş zamanında geçerler.

Kutupsal yörüngeli uydular, atmosfer fiziği, çevre, tarım, çok kısa vadeli hava tahmini, hava-deniz etkileşimi ve meteorolojik amaçlı olarak kullanılmaktadır. Dünyanın %70'inin sularla kaplı olması ve kara alanlarındaki birçok bölgenin üzerinde nadiren yerleşim bulunması nedeniyle kutupsal yörüngeli uydu sistemi geleneksel gözlem sistemleriyle yeterli derecede kapsanamayan, özellikle güney yarıküre, Arktik ve Antarktik gibi yüksek enlemlerde yüzey ve atmosferik sıcaklık profillerindeki boşlukları doldurmak için gerekli verileri sağlarlar. Bu uydular, yakın kutupsal yörüngedeki ardışık dönüşleri ile Dünyanın bütün kısımlarından kayıt yaparak veri aktarırlar. Kutupsal yörüngeli uydular, sabit yörüngeli uydulara göre uzaysal ve spektral olarak daha yüksek çözünürlükte veri sağlarlar. Bu özellikleri nedeniyle kutupsal yörüngeli uydu verileri, günlük küresel bulut örtüsü, güvenilir yüzey sıcaklığı ile sıcaklık ve atmosferdeki düşey değişim konularında veri elde etmekte kullanılır (MGM).

Kutupsal yörüngeli Suomi-NPP uydusu uzaya fırlatılacak gelecek nesil uydu sisteminin kritik bir ilk adımıdır. NASA (National Aeronautics and Space Administration) tarafından geliştirilen ve NOAA (National Oceanic and

Atmospheric Administration) tarafından yönetilen uydu 28 Ekim 2011'de Kaliforniya'daki Vandenberg tesisinden Delta-2 roketi ile fırlatılmıştır. Suomi-NPP uydusu 2100 kg ağırlığındadır ve çıkış evresi için (ascending node) ekvatoru yerel saat ile 13.30'da geçmektedir. Bu uydu dünyanın etrafındaki yörüngesinden günde yaklaşık 14 defa geçiş yapar ve neredeyse yer yüzeyinin tamamına yakını kayıt edilir. Uydu gezegenimizin yönetimi için çeşitli bilimsel cihazlar taşımaktadır. Bunlar beş algılama cihazı ile bir de yer destek ekipmanı ve simülatöründen oluşmaktadır. Uydunun taşıdığı algılayıcı cihazlar daha önce NASA'nın değişik uydularında kullandığı ATMS (Advanced Technology Microwave Sounder), CrIS (Cross-track Infrared Sounder), OMPS (Ozon Mapping Profiler Suite), ve CERES (Clouds and the Earth's Radiant Energy System) ile yeni bir sensör olan VIIRS algılayıcısıdır (NASA).

Çizelge 3.3. VIIRS algılayıcısının özellikleri.

Yörünge	824 km, güneş eş-zamanlı, yakın kutupsal
Tarama	33.6 rpm, cross-track
Görüntü boyutları	3000 km X 13 km (across track X along track)
Boyutlar	1.3m X 1.4m X 0.9m
Ağırlık	263 kg
Güç	154 W
Veri oranı	10.4 Mbps
Kuantizasyon	12 bit
Tasarlanan ömür	7 yıl

Kutupsal yörüngeli Suomi-NPP uydusunda bulunan VIIRS algılayıcısı görünür ve kızılötesi görüntüleme ile yer, atmosfer, buzullar ve okyanusların radyometrik ölçümleri için taramalı bir radyometredir. VIIRS verileri bulut ve aerosol özelliklerinin, okyanus, deniz ve yeryüzü sıcaklığının, buz hareketleri ve sıcaklığının, yangınlar ve yerin albedosunun ölçümü için kullanılmaktadır. VIIRS algılayıcısı AVHRR (Advanced Very High Resolution Radiometer), MODIS,

SeaWiFS (Sea-viewing Wide Field-of-view Sensor) ve OLS (Operational Linescan System) cihazlarının geliştirilmiş ve bu cihazların devamıdır. VIIRS cihazı da MODIS gibi okyanus, yer, aerosol ve bulut için araştırmacılara ve operasyonel kullanıcılara disiplinler arası veri sağlayan bir sensördür. VIIRS verileri AVHRR, MODIS ve diğer sensör verilerinin devamı olarak kullanılabilir. VIIRS algılayıcısı iklim değişikliği için kritik önemde sürekli (kesintisiz) veri kaydı yapar ve global iklim değişikliği konusundaki bilgilerin gelişim için bu veriler kullanılabilir. VIIRS algılayıcı 824 km yükseklikteki yörüngesinden, 3000x13 km² boyutlarında görüntü kaydı yapmaktadır ve tasarlanan ömrü 7 yıldır. VIIRS algılayıcısının özellikleri Çizelge 3.3'te verilmiştir (NASA).

VIIRS algılayıcısı 22 kanala sahip ve 0.412 ile 12.012 µm arasında kayıt yapmaktadır. Bu kanallar M (Moderate resolution), I (Imaging resolution) ve DNB (Day/Night band) olmak üzere üç gruba ayrılmıştır. 16 M kanalı, beş I kanalı ve bir tanede DNB kanalı mevcuttur. M kanalları ve DNB kanalı 750 m yersel çözünürlüğe sahip iken I kanalları 375 m yersel çözünürlüğe sahiptir. Bu kanallara ait bilgilerden merkezi dalga boyları ve kullanıldığı öncelikli alanlar Çizelge 3.4'te verilmiştir. M kanalları 11 solar ve 5 termal kanaldan, I kanalları ise 3 solar ve 2 termal kanaldan oluşmaktadır. DNB pankromatik kanalı 0.50 ile 0.90 µm spektral genişlikte gece-gündüz kayıt yapan kanaldır. M1-M7 kanalları öncelikle okyanus ve aerosol uygulamaları için, M8, M9, M11, M14, I4 ve I5 kanalları bulutlar için, M12, M13, M15 ve M16 öncelikle deniz yüzey sıcaklığı için, I3 ve M10 kar için ve I2 ve I1 NDVI (Normalized Difference Vegetation Index) ve görüntüleme için kullanılır. Bu kanal kayıtlarından elde edilen veriler üç grupta toplanmıştır. Bunlar RDR (Raw Data Records), SDR (Sensor Data Records) ve EDR (Environmental Data Records) verileridir. RDR uydu ve sensörün yönetimi için mühendislik ve bakım verisi ile SDR üretimi için bilimsel veriyi içerir. SDR kalibre edilmiş radyans ve reflektans yada parlaklık sıcaklığı verisidir ve EDR algoritmalarının girdisidir (NOAA, 2013).

Çizelge 3.4. VIIRS algılayıcısının bandları

VIIRS Kanal İsimleri	Merkez Dalga Boyu (μm)	Öncelikli Uygulama Alanı
M01	0.412	Okyanus, Aerosol
M02	0.445	Okyanus, Aerosol
M03	0.488	Okyanus, Aerosol
M04	0.555	Okyanus, Aerosol
M05	0.672	Okyanus, Aerosol
M06	0.746	Atmosferik düzeltme
M07	0.865	Okyanus, Aerosol
M08	1.240	Bulut parçacık boyutu
M09	1.378	Sirrus bulut örtüsü
M10	1.610	Kar örtüsü
M11	2.250	Bulutlar
M12	3.700	Deniz yüzey sıcaklığı
M13	4.050	Deniz yüzey sıcaklığı, Yangınlar
M14	8.550	Bulut tepe özellikleri
M15	10.763	Deniz yüzey sıcaklığı
M16	12.012	Deniz yüzey sıcaklığı
I01	0.640	Görüntüleme, Vejetasyon
I02	0.865	Vejetasyon
I03	1.610	İkili (Binary) kar haritası
I04	3.740	Görüntüleme, Bulutlar
I05	11.450	Bulut görüntüleme
DNB	0.700	Görüntüleme

VIIRS kayıtlarından üretilen RDR verileri, VIIRS'in öncülü olan MODIS'in Level 0 verilerine, SDR MODIS Level 1 verilerine ve EDR MODIS Level 2 verilerine karşılık gelmektedir. Üst seviye VIIRS ürünlerinden EDR veri grubu içerisinde yer alan ürünlerin bir listesi aşağıda verilmiştir (NOAA, 2013).

Ø Yer:

- Ø Active Fires – Aktif Yangınlar
- Ø Land Surface Albedo – Yer Yüzey Albedosu
- Ø Land Surface Temperature – Yer Yüzey Sıcaklığı
- Ø Ice Surface Temperature – Buz Yüzey Sıcaklığı
- Ø Snow Ice Characterization – Kar Buz Karakteristiği
- Ø Snow Cover/Depth – Kar Kapalılığı/Derinliği
- Ø Vegetation Index – Bitki İndeksi
- Ø Surface Type – Yüzey Tipi

Ø Okyanus:

- Ø Sea Surface Temperature – Deniz Yüzey Sıcaklığı
- Ø Ocean Color/Chlorophyll – Okyanus/Klorofil

Ø Bulutlar:

- Ø Imagery – Görüntüleme
- Ø Cloud Optical Thickness - Bulut Optik Kalınlığı
- Ø Cloud Effective Part Size – Bulut Etkin Kısmının Büyüklüğü
- Ø Cloud Top Parameters – Bulut Tepe Parametreleri
- Ø Cloud Base Height – Bulut Taban Yüksekliği
- Ø Cloud Cover/Layers – Bulut Kapalılığı/Katmanları

Ø Aerosoller:

- Ø Aerosol Optical Thickness – Aerosol Optik Kalınlığı
- Ø Aerosol Particle Size – Aerosol Parçacık Büyüklüğü
- Ø Suspended Matter – Asılı Madde

3.1.4.1. VIIRS SDR Verisi

SDR (Level 1B) radyometrik kalibrasyon algoritması, RDR içerisindeki VIIRS algılayıcısının kayıtlarından elde edilen sayı değerlerini (Digital Number - DN) radyans ile reflektans ya da parlaklık sıcaklığına dönüştürür. SDR radyans ile reflektans ya da parlaklık sıcaklığı verilerinin yanı sıra, piksel coğrafi koordinatları ile arazi yüksekliği, uydu-yer aralığı gibi ilgili geometri verilerini de içermektedir. 22 VIIRS kanalının 14'ü solar (11 tane M ve 3 tane I), 7'si termal (5 tane M ve 2 tane I) ve DNB kanalı ise geniş-band kanaldır. Bu kanallara uygulanan kalibrasyon algoritmaları da farklılık göstermektedir (NOAA, 2013).

Termal Kanallar için Kalibrasyon Algoritması: VIIRS algılayıcısının yaptığı tarama termal kanalların bütün pikselleri için 12 bit sayı olan değerler (DN) üretir. Kalibrasyon katsayıları uygulanmadan önce bu değerlerden DN_{offset} çıkarımı yapılır ve dn_j detektörün ölçtüğü değerler için diferansiyeli $dn = DN - DN_{offset}$ şeklinde bulunur. θ tarama açısında ve B termal kanalı için radyans $L(\theta, B)$ olmak üzere eşitlik 3.11 kullanılarak hesaplanır:

$$L(\theta, B) = \frac{(1-RVS(\theta, B)) \left[\left(\frac{1}{\rho_{rta}(\lambda)} - 1 \right) * L(T_{rta}, \lambda) - \left(\frac{L(T_{ham}, \lambda)}{\rho_{rta}(\lambda)} \right) \right] + F * \sum_{j=0}^2 c_j(T_{det}, T_{elec}) * dn_j}{RVS(\theta, B)} \quad (3.11)$$

burada $RVS(\theta, B)$ tepki fonksiyonu (response versus scan function), $\rho_{rta}(\lambda)$ RTA'nın (Rotating Teleskop Assembly – Dönen Teleskop Montajı) spektral reflektansı, $L(T, \lambda)$ Plank fonksiyonuna göre kara cismin spektral radyansı, F radyans katsayıları için faktör ve $c_j(T_{det}, T_{elec})$, kalibrasyon güncellemesinden sonraki tepki fonksiyonunun j. sıradaki katsayıya bağlı sıcaklığıdır.

Solar Kanallar için Kalibrasyon Algoritması: VIIRS algılayıcısı θ tarama açısında ve B solar kanalı için radyans $L(\theta, B)$ olmak üzere eşitlik 3.12 kullanılarak hesaplanır:

$$L(\theta, B) = \frac{F * \sum_{j=0}^2 c_j * dn_j}{RVS(\theta, B)} \quad (3.12)$$

θ_{SE} güneş zenit açısı, d_{SE} yıllık ortalama Dünya-Güneş uzaklığı, $E_{sun}(\lambda, d_{SE})$ spektral irradyans ve $L(\theta, B)$ radyans olmak üzere reflektans, $\rho(\theta, B)$ eşitlik 3.13 ile hesaplanır.

$$\rho(\theta, B) = \frac{\pi * L(\theta, B)}{\cos(\theta_{SE}) * E_{sun}(\lambda, d_{SE})} \quad (3.13)$$

DNB Kanalı için Kalibrasyon Algoritması: VIIRS algılayıcısının DNB kanalı için radyans L_{DNB} , $c_j[agg(N_f), N_p, N_G]$ kalibrasyon katsayıları ve $dn = DN - DN[N_F, N_P, N_G]$ olmak üzere eşitlik 3.14 ile hesaplanır.

$$L_{DNB} = \frac{\sum_{j=0}^2 c_j [agg(N_f), N_p, N_G] * dn_j}{RVS[N_F, N_P, N_G]} \quad (3.14)$$

3.2. Metod

3.2.1. Öznitelik Seçimi

Regresyon veya sınıflandırma amaçlı olsun bir uygulamada, bilgi değeri yüksek olduğu düşünülen tüm gözlem veya ölçme verileri girdi olarak alınır. Öte yandan geliştirilecek modelin karmaşıklığı girdi sayısına bağlıdır. Girdi sayısı modeli eğitmenin zaman ve uzay karmaşıklığını ve gerekli öğrenme örneği sayısını belirleyen bir unsurdur. Çoğu öğrenme algoritmasında karmaşıklık, veri örnekleme büyüklüğüne ve girdi boyutuna bağlıdır. Eğer bir girdinin ayırt edici olmadığı bilirse onu elde etmek veya ölçmek için gereken uğraş ve bedelden tasarruf edilebilir. Küçük veri setlerinde daha basit modeller daha güvenilir olur. Veri seti daha az değişkenle açıklandığında bilgi çıkarımı daha kolay, kontrol edilebilirliği daha yüksek olur (Alpaydın, 2013).

Veri setindeki özniteliklerin önemli bir alt kümesini kullanıp kalanları atan yönteme öznitelik seçimi ve asıl öznitelikleri birleştirerek az sayıda yeni öznitelik oluşturan yöntemlere ise öznitelik çıkarma denir. Öznitelik seçiminde N adet değişkenden en çok bilgi içeren r tanesi bulunur ve diğer $(N-r)$ tanesi atılır. Öznitelik çıkarımında, N değişken birleştirilerek $r < N$ tane yeni değişken oluşturulur. Bu yöntemler çıktı bilgisini kullanıp kullanmadıklarına göre eğitilmiş ya da eğitimsiz olabilirler. (Alpaydın, 2013).

Öznitelik seçimi veri seti içerisinde yeni bir öznitelik alt kümesi elde etme işlemidir. Altküme seçiminde amaç eldeki özniteliklerin en iyi alt kümesini bulmaktır. Öznitelik seçimi ile büyük veri setlerinden önemsiz veya az önemli verilerin elenerek önemli olanlarının kullanılmasıyla modellerin başarısının artırılması amaçlanır. Özellik seçiminin faydaları, modelin doğruluğunu yükseltmek, eğitim süresini azaltmak ve ezberlemeyi (overfitting) önlemek olarak sıralanabilir. Öznitelik seçme algoritmaları başlıca üç grupta ifade edilmektedir. Bunlar süzgeç (Filter), sarmalama (Wrapper) ve gömülü (Embedded) yöntemlerdir (Kohavi ve John, 1997; Guyon ve Elisseeff, 2003).

Süzgeç yöntemlerinde herhangi bir öğrenme algoritması kullanılmaksızın, bilgi, bağımlılık ve tutarlılık gibi ölçümler kullanılarak öznitelik seçimi yapılır. Bu yöntem sarmalama yöntemlerine göre daha az karmaşık ve hızlıdır (Guyon ve Elisseeff, 2003). Bilgi kazancı, T-test, relief gibi yaygın kullanılan algoritmalar süzgeç yöntemlerindedir. Sarmalama yöntemlerinde ise öznitelik seçimi için bir öğrenme algoritması kullanılır. Genetik algoritmalar ve DVM sarmalama yöntemlere, karar ağaçları ise gömülü yöntemlere örnek verilebilir.

Bu çalışmada yinelemeli öznitelik eleme (Recursive Feature Elimination - RFE) yöntemi kullanılmıştır. RFE Guyon ve ark (2002) tarafından geliştirilmiş bir sarmal tabanlı öznitelik seçim algoritmasıdır. N boyutlu veri setinde $r < N$ olmak üzere r boyutlu en iyi alt kümeyi bulmayı amaçlamaktadır. RFE lineer DVM kullanan bir algoritmadır. Algoritma DVM'nin düzenleme terimi olan $\frac{1}{2} \|\omega\|^2$

ifadesini özellik sıralama kriteri olarak kullanmaktadır. Her bir iterasyonda, ağırlık vektörüne (ω) ait katsayılar tüm özniteliklerin sıralama puanının hesaplanmasında kullanılır. En küçük sıralama puanına sahip özellik elenir.

3.2.2. Destek Vektör Makineleri

DVM Vapnik tarafından geliştirilmiş eğitilmiş öğrenmeye dayanan yapay öğrenme algoritmasıdır. Ortaya konulduğu zamandan beri örüntü tanıma, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılmaktadır. Öncelikle sınıflandırma için geliştirilen yöntem daha sonra Cortes ve Vapnik tarafından regresyon problemlerinin çözümü için genişletilmiştir. DVM öğrenmesi genel hatanın üst sınırını minimize eden yapısal risk minimizasyonu prensibine dayanır (Cortes ve Vapnik, 1995; Vapnik ve ark, 1997). DVM lineer ve lineer olmayan problemlere uygulanabilir. Doğrusal ayrılamayan veri problemlerinde daha yüksek boyutlu özellik uzayı lineer olmayan bir kernel metoduyla değerlendirilir (Vapnik ve Mukherjee, 2000; Ch ve ark, 2014). Eğitim verisi kuadratik programlama yardımıyla doğrudan yüksek boyutlu özellik uzayına haritalanır. Bu uzayda bir veya daha fazla hiperdüzlem oluşturulur. Bu hiperdüzlemler destek vektörleri olarak adlandırılan seçilmiş veriler dikkate alınarak oluşturulan maksimum aralığa (marjin) sahiptir. Yüksek boyutlu uzaydaki çözüm bir dışbükey optimizasyona dönüştürülür. Bu nedenle yerel minimum problemleri yoktur. YSA gibi çok katmanlı algılayıcıların tersine, DVM çözümü tektir. Kernel metotları özellikle regresyon problemlerinde büyük öneme sahiptir. DVM'nin bu avantajları ve verimliliği onu mühendislik ve bilimsel problemler için popüler bir metot yapmaktadır (Kaba ve ark, 2016).

Vapnik teorisine dayanan DVM denklemleri aşağıda eşitlik 3.15'dan eşitlik 3.21'a kadar ifade edilmiştir (Smola ve Schölkopf, 2004; Kim ve ark, 2012; Ch ve ark, 2014). Örnek verinin girdi uzay vektörü x_i , çıktı değerler d_i ve eğitim veri sayısı l olmak üzere $\{x_i, d_i\}_i^l$ şeklinde bir veri seti ele alalım. DVM eşitlik 3.15 ve 3.21 ile verilen fonksiyona yakınsamayı amaçlar.


$$f(x) = \langle \omega, x \rangle + b \quad (3.15)$$

burada ω normal vektörü ve b bir skaleri (bias) ifade eder. Tahminin niceliği kayıp fonksiyonu $L_\varepsilon(x_i, d_i)$ ile ölçülür. DVM Vapnik tarafından önerilen yeni bir ε -duyarlı kayıp fonksiyonu kullanır. Böylece hem ε değeri kadar olan hatalar göz ardı edilmekte, hem de daha büyük hataların etkisi doğrusal olmaktadır.

$$L_\varepsilon(x_i, d_i) = \begin{cases} \mathbf{0}, & |d_i - f(x)| < \varepsilon \\ |d_i - f(x)| - \varepsilon, & \text{diğer} \end{cases}$$

$$R_{SVMs}(C) = \frac{1}{2} \|\omega\|^2 + C \frac{1}{l} \sum_{i=1}^l L_\varepsilon(x_i, d_i) \quad (3.16)$$

$R_{SVMs}(C)$ düzenlenmiş risk fonksiyonunu, $\frac{1}{2} \|\omega\|^2$ düzenleme terimini ve $C \frac{1}{l} \sum_{i=1}^l L_\varepsilon(x_i, d_i)$ ampirik hatayı ifade eder. C düzenleme terimi ile ampirik hata arasındaki farkı ayarlamak için kullanılan hata ceza faktörüdür. Hiper düzlemin iki yanında sapma olabileceği için kenardan sapmayı gösteren $\xi_i, \xi_i^* \geq \mathbf{0}$ artık değişkenleri tanımlanır. Şekil 3.6 lineer olmayan problemin üst boyuta haritalanmasını ve ε kayıp fonksiyonu ile ξ artık değişkeni göstermektedir. ω ve b parametreleri üst ve alt ilave sapmayı temsil eden ξ_i, ξ_i^* değişkenlerinin denkleme girmesiyle ve eşitlik 3.16'daki düzenlenmiş risk fonksiyonunun minimize edilmesiyle bulunur (Chen ve ark, 2011; Ch ve ark, 2014).



Şekil 3.6. Verilerin üst boyutlu uzaya haritalanması (Fletcher, 2009)

$$\text{Minimize } R_{SVMs}(\omega, \xi_i, \xi_i^*) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (3.17)$$

$$\text{Kısıtlamalar; } \begin{cases} d_i - \langle \omega, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle \omega, x_i \rangle + b - d_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, \quad i = 1, 2, 3, \dots, l \end{cases}$$

Eşitlik 3.16'nın düzenlenmesiyle eşitlik 3.17 elde edilir. Eşitlik 3.17'ye Lagrange çarpanlarının eklenmesi ve optimum kısıtlamalar ile eşitlik 3.18 (Lagrange denklemi) elde edilir (Smola ve Schölkopf, 2004; Basak ve ark, 2007).

$$L = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - d_i + \langle \omega, x_i \rangle + b) - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* + d_i - \langle \omega, x_i \rangle - b) - \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \quad (3.18)$$

burada $\alpha_i, \alpha_i^*, \eta_i$ ve $\eta_i^* \geq 0$ ve bu katsayıları Lagrange çarpanları denir. ω, b, ξ_i ve ξ_i^* değişkenlerine göre L denkleminin kısmi türevi alınır aşağıdaki eşitlikler elde edilir. (Smola ve Schölkopf, 2004; Basak ve ark, 2007).

$$\frac{\partial L}{\partial b} = \sum_{i=1}^l (\alpha_i^* - \alpha_i) = \mathbf{0} \quad (3.19a)$$

$$\frac{\partial L}{\partial \omega} = \omega - \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i = \mathbf{0} \quad (3.19b)$$

$$\frac{\partial L}{\partial \xi_i} = C - \alpha_i - \eta_i = \mathbf{0} \quad (3.19c)$$

$$\frac{\partial L}{\partial \xi_i^*} = C - \alpha_i^* - \eta_i^* = \mathbf{0} \quad (3.19d)$$

eşitlik 3.19c ve 3.19d denklemlerinden η_i ve η_i^* katsayıları C , α_i ve α_i^* cinsinden yazıldığında bu katsayılar elenerek eşitlik 3.19'daki ifadeler eşitlik 3.18'de yerlerine yazılmasıyla eşitlik 3.20 (dual optimizasyon problemi) elde edilir. eşitlik 3.20 $\sum_{i=1}^l (\alpha_i^* - \alpha_i) = \mathbf{0}$ ve $\alpha_i, \alpha_i^* \in [0, C]$ koşulları ile çözümlerse, ε tüpüne düşen örnekler için $\alpha_i = \alpha_i^* = \mathbf{0}$ olur. Bunlar istenilen duyarlılıkta tahmin edilen değerlerdir. $\alpha_i > \mathbf{0}$ ve $\alpha_i^* > \mathbf{0}$ durumunda, değerler ε tüpünün sınırında (0 ile C aralığında) veya dışında olabilir. Bu durumda yeterince iyi tahmin yapılmamıştır.

$$\text{Maximize} \left\{ -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - \sum_{i=1}^l \varepsilon (\alpha_i + \alpha_i^*) + \sum_{i=1}^l d_i (\alpha_i - \alpha_i^*) \right\} \quad (3.20)$$

eşitlik 3.19b düzenlenirse ω aşağıdaki gibi elde edilir ve ω değeri eşitlik 3.15'de yerine yazılırsa eşitlik 3.21 elde edilir.

$$\omega = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i$$

$$f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (3.21)$$

Eşitlik 3.20'de $\langle x_i, x_j \rangle$ çarpımı yerine bir $K(x_i, x_j)$ çekirdeği ve (x, x_i) yerine $K(x, x_i) = \varphi(x) \varphi(x_i)$ çekirdek (kernel) fonksiyonu kullanılarak lineer olmayan regresyon işlemi gerçekleştirilir. Denklemdaki diğer bilinmeyen b (bias) katsayısı Karush-Kuhn-Tucker (KKT) şartları ile bulunur (Smola ve Schölkopf, 2004).


$$\begin{cases} \alpha_i(\varepsilon + \xi_i - d_i + \langle \omega, x_i \rangle + b) = 0 \\ \alpha_i^*(\varepsilon + \xi_i^* + d_i - \langle \omega, x_i \rangle - b) = 0 \end{cases} \text{ ve } \begin{cases} (C - \alpha_i)\xi_i = 0 \\ (C - \alpha_i^*)\xi_i^* = 0 \end{cases}$$

KKT koşullarından iki sonuç çıkarılır. Birincisi örnek veriler sadece $\alpha_i = C$ ve $\alpha_i^* = C$ iken ε tüpü içinde bulunur. İkincisi ise $\alpha_i * \alpha_i^* = 0$, aynı anda sıfırdan farklı α_i ile α_i^* değişkenleri bulunmaz. Bu ifadelerden $\xi_i^* = 0$ iken b için aşağıdaki sonuçlar çıkarılır.

$$\begin{cases} b = d_i - \langle \omega, x_i \rangle - \varepsilon, & \alpha_i \in (0, C) \text{ ise} \\ b = d_i - \langle \omega, x_i \rangle + \varepsilon, & \alpha_i^* \in (0, C) \text{ ise} \end{cases}$$

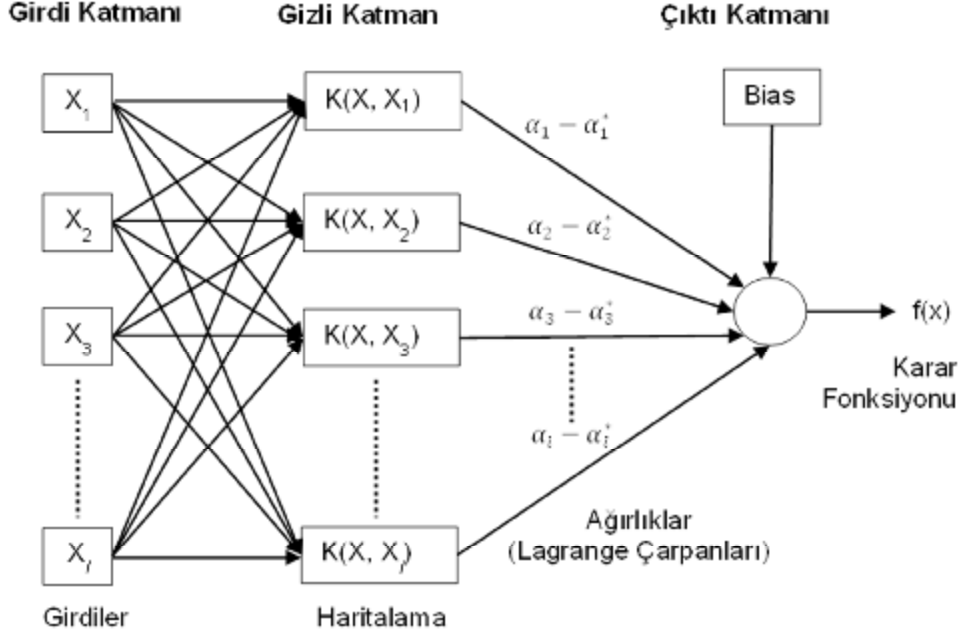
Şekil 3.7 lineer olmayan DVM'ne örnek verilmiştir. Grafikte kesikli çizgiler ε sınırlarıdır ve kesikli çizgiler arasında kalan bölgeye ε tüpü denir. DVM ile yapılan tahminin doğruluğu C , ε , ve çekirdek fonksiyonuna bağlıdır. C parametresi model karmaşıklığı ile optimizasyon formülünde tolere edilenden daha büyük sapmaların derecesi arasındaki değişimi belirler. Eğer C çok büyükse, optimizasyon formülündeki model karmaşıklığına bakılmaksızın, amaç sadece ampirik hatayı minimize etmek olacaktır. ε ise destek vektörlerinin sayısını etkiler. Büyük ε , daha az destek vektörü seçerken, bir yandan da daha monoton (flat) tahmin yapar. DVM'nde yaygın kullanılan çekirdek fonksiyonlarından RBF, lineer,

polinom, ve sigmoid fonksiyonlarının denklemleri aşağıda verilmiştir. DVM'nin mimarisi de Şekil 3.8'te verilmiştir.



Şekil 3.7. Lineer olmayan DVM (Granata ve ark, 2016)

RBF:	$\exp(-\gamma x - x_i ^2)$
Lineer:	$\langle x, x_i \rangle$
Polinom:	$(\gamma \langle x, x_i \rangle + r)^d$
Sigmoid:	$\tanh(\gamma \langle x, x_i \rangle + r)$



Şekil 3.8. DVM'nin mimarisi

3.2.3. Hata Hesabının Tanımlanması

Bu çalışmada kullanılan modellerin başarısını tespit etmek ve sonuçları değerlendirmek için literatürde yaygın olarak kullanılan hata hesaplama yöntemlerinden faydalanılmıştır. Bunlar; MBE (Mean Bias Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), RMSE (Root Mean Square Error), yüzdelik RMSE (RMSE% ve R^2 (Determination of coefficient) olup eşitlik 3.22'den 3.27'ye kadar verilen denklemlerle hesaplanırlar. MBE değeri yapılan tahminin eksik veya fazla olduğu bilgisini içerir. Eğer MBE negatif ise yapılan tahminin gerçek değerden az, pozitif ise yapılan tahminin gerçek değerden fazla olduğu anlaşılır. MAE ve RMSE değerleri ise ortalama hatanın büyüklüğünü verirler. R^2 iki nicelik arasındaki ilişkinin büyüklüğünü ifade eder.

$$MBE = \frac{\sum_{i=1}^n (E_i - O_i)}{n} \quad (3.22)$$

$$\text{MAE} = \frac{\sum_{i=1}^n |E_i - O_i|}{n} \quad (3.23)$$

$$\text{MAPE} = \frac{100}{n} * \sum_{i=1}^n \left| \frac{E_i - O_i}{O_i} \right| \quad (3.24)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (3.25)$$

$$\text{RMSE}(\%) = \frac{100 * n}{\sum_{i=1}^n (O_i)} * \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (3.26)$$

$$R^2 = \frac{[\sum_{i=1}^n (E_i - \bar{E})(O_i - \bar{O})]^2}{\sum_{i=1}^n (E_i - \bar{E})^2 \sum_{i=1}^n (O_i - \bar{O})^2} \quad (3.27)$$

Bu formüllerde n toplam örnek sayısını, E_i model ile tahmin edilen değerleri, O_i ölçülen değerleri, \bar{E} tahmin edilen değerlerin ortalamasını, \bar{O} ölçülen değerlerin ortalamasını ifade etmektedir. Bu çalışmada E_i tahmin edilen güneşlenme süresine, \bar{E} tahmin edilen güneşlenme sürelerinin ortalamasına, O_i meteorolojik istasyonlarda ölçülen güneşlenme süresine, \bar{O} ise meteorolojik istasyonlarda ölçülen güneşlenme sürelerinin ortalamasına karşılık gelmektedir.

4. BULGULAR VE TARTIŞMA

4.1. Yer ve Coğrafik Verilerin Hazırlanması

Bu çalışmada GS'ni yüksek doğrulukla tahmin etmek amacıyla GS ile ilişkili 27 tane günlük parametre ve 26 tane aylık parametre ele alınmıştır. Bunlardan ilk üçü zaman ifadesi (yıl, ay, gün), diğer üçü konumu (enlem, boylam, yükseklik) ve beş tanesi de coğrafik değişken olarak adlandırılan julien günü, deklinasyon açısı, güneş saat açısı, gün uzunluğu (maksimum güneşlenme süresi) ve atmosfer dışı güneş ışınımıdır. Geriye kalan girdiler ise uydudan elde edilen yansıma ve parlaklık sıcaklığı verileridir.

Çalışmada MGM'ye ait 131 yer istasyonundan 2013-2015 yıllarını içeren günlük GS verileri kullanılmıştır. Bu veriler geleneksel olarak ölçülen Campbell-Stokes helyograf değerleri ve tam otomatik istasyonlarda kullanılan yeni dijital cihazın ölçümleridir. Çalışılan üç yıllık zaman dilimi göz önüne alınarak, eksik bilgi içeren ve iki yıldan (%66, 730 adet) az verisi olan istasyonlar çalışmada kullanılmamıştır. Bu durumda olan istasyonların elenmesiyle sürekli veriye sahip 124 istasyonun verisiyle çalışılmıştır. Geriye kalan 124 istasyonun verisi günlük toplam ve aylık ortalama olarak düzenlenmiştir.

GS verisinin düzenlenmesiyle bu istasyonların konumuna ve verilerin zamanına karşılık gelen günlük ve aylık coğrafik veriler de hesaplanarak modellerde kullanılacak veri setinin ilk bölümü tablo halinde oluşturulmuştur. Günlük tahmin için 45 adet istasyonun verisi aylık tahmin için ise 120 adet istasyonun verisi kullanılmıştır. Kullanılan bu istasyonların konumları Şekil 4.1 ve Şekil 4.2'deki haritalarda verilmiştir. Haritalar incelendiğinde, günlük tahminde kullanılan istasyonlar daha çok iç Anadolu ve güneydoğu Anadolu bölgelerinde yoğunlaşmıştır. Diğer bölgelerde ise az sayıda istasyon bulunmaktadır. Aylık tahminde kullanılan istasyonlar ise ege ve Karadeniz bölgelerinin dağlık iç kısımları hariç bütün iklim koşullarını yansıtabilecek şekilde ülke geneline dağılmıştır.



Şekil 4.1. Günlük tahminde kullanılan istasyonların konumları



Şekil 4.2. Aylık tahminde kullanılan istasyonların konumları

Çalışmada kullanılan istasyonlara ait istasyon kodları (İK), konum bilgilerinden enlem (E), boylam (B) ve yükseklik (Y) ile istasyonun bulunduğu il ve ilçe isimleri günlük tahminde kullanılan istasyonlar için Çizelge 4.1 ve aylık tahminde kullanılan istasyonlar için ise Ek-1’de verilmiştir.

Çizelge 4.1. Günlük tahmin için kullanılan istasyonlar


İK	E (N°)	B (E°)	Y (m)	Şehir	İlçe
17026	42.0299	35.1545	32	SINOP	MERKEZ
17040	41.04	40.5013	3	RIZE	MERKEZ
17045	41.1752	41.8187	625	ARTVIN	MERKEZ
17056	40.9585	27.4965	4	TEKIRDAG	MERKEZ
17070	40.7329	31.6022	743	BOLU	MERKEZ
17074	41.371	33.7756	800	KASTAMONU	MERKEZ
17088	40.4598	39.4653	1216	GUMUSHANE	MERKEZ
17112	40.141	26.3993	6	CANAKKALE	MERKEZ
17130	39.9727	32.8637	891	ANKARA	KECIOREN
17162	39.185	36.0805	1182	SIVAS	GEMEREK
17172	38.4693	43.346	1675	VAN	MERKEZ
17190	38.738	30.5604	1034	AFYONKARAHISAR	MERKEZ
17192	38.3705	33.9987	970	AKSARAY	MERKEZ
17199	38.3367	38.2173	950	MALATYA	MERKEZ
17201	38.6443	39.2561	989	ELAZIG	MERKEZ
17227	37.8167	27.8873	32	AYDIN	CILDIR
17239	38.3688	31.4297	1002	KONYA	AKSEHIR
17240	37.7848	30.5679	997	ISPARTA	MERKEZ
17242	37.6777	31.7463	1141	KONYA	BEYSEHIR
17246	37.1932	33.2202	1018	KARAMAN	MERKEZ
17250	37.9587	34.6795	1195	NIGDE	MERKEZ
17262	36.7085	37.1123	640	KILIS	MERKEZ
17275	37.3063	40.7235	1040	MARDIN	MERKEZ
17285	37.5745	43.7388	1727	HAKKARI	MERKEZ
17287	37.5209	42.4523	1350	SIRNAK	MERKEZ
17292	37.2095	28.3668	646	MUGLA	MERKEZ
17602	41.7526	32.3827	73	BARTIN	AMASRA

Çizelge 4.1'in Devamı

17614	40.4088	27.06	56	CANAKKALE	BIGA
17624	41.143	37.293	16	ORDU	UNYE
17718	39.7728	40.3843	1429	ERZINCAN	TERCAN
17734	39.3618	38.1142	1121	SIVAS	DIVRIGI
17749	38.4639	27.3705	208	IZMIR	KEMAL PASA
17754	39.0788	33.0657	1005	KONYA	KULU
17760	39.1897	35.2532	1070	YOZGAT	BOGAZLIYAN
17776	38.9597	41.0503	1366	BINGOL	SOLHAN
17780	39.1337	42.5308	1540	MUS	MALAZGIRT
17789	38.6237	27.0433	10	IZMIR	MENEMEN
17802	38.7251	36.3904	1542	KAYSERİ	PINARBASI
17806	38.6907	39.926	1000	ELAZIG	PALU
17836	38.3713	35.4745	1204	KAYSERİ	DEVELİ
17866	38.024	36.4823	1344	KAHRAMANMARAS	GOKSUN
17906	37.548	34.4867	1453	NIGDE	ULUKISLA
17944	37.3651	38.5134	622	SANLIURFA	BOZOVA
17968	36.8406	40.0307	360	SANLIURFA	CEYLANPINAR
17978	36.8898	34.9558	12	MERSİN	TARSUS

Çalışmada kullanılan coğrafik verilerin yıl boyunca olan değişimini gösteren grafikler Şekil 4.3'te verilmiştir. Grafiklerde yatay eksen julien günü, dikey eksenlerde diğer coğrafik parametreleri ifade etmektedir. Grafikler 124 istasyonun çalışılan üç yıllık zaman dilimine (2013-2015) ait GS ve uydu verilerinin bulunduğu günlerde hesaplanan coğrafik parametrelerin değerlerini içermektedir. Deklinasyon açısı sadece julien gününe bağlı olup radyan biriminde hesaplanmıştır. Her bir istasyon için 21 Aralıkta -0.409 minimum ve 21 Haziranda 0.409 maksimum değerini almaktadır. Bir diğer coğrafik parametre olan güneş saat açısının gün batımındaki değerleri kullanılmıştır. Enlem ve deklinasyon açısına

(dolayısıyla julien gününe) bağlı olarak değişmektedir ve radyan biriminde hesaplanmıştır. Çalışılan istasyonlar için güneş saat açısı 1.1694 değeri ile en küçük 21 Aralıkta ve 1.9722 değeri ile en büyük değeri 21 Haziranda Sinop ilinde almaktadır. Güneşlenme süresinin alabileceği maksimum değer olan gün uzunluğu ise güneş saat açısına bağlı olarak hesaplanmakta ve değişimi de güneş saat açısı ile aynıdır. En küçük değeri 21 Aralıkta 8.9339 saat, en büyük değeri 21 Haziranda 15.0663 saat olarak Sinop ilinde almaktadır. Gün uzunluğunun ortalama değeri bu veri seti için 12 saattir. Atmosferik etkilerin olmadığı şartlarda yere ulaşacak enerji miktarı olan atmosfer dışı güneş ışınımı değerleri ise 12.2624 ile 41.9135 MJ/m²/gün arasında değişmektedir. Bu değerler veri seti içerisinde en yüksek enleme sahip olan Sinop iline aittir. Atmosfer dışı güneş ışınımının ortalama değeri de bu veri seti için 28.5799 MJ/m²/gün olarak bulunmuştur.



Şekil 4.3. Coğrafik verilerin yıllık değişimi

4.2. Sabit Yörüngeli Uydu Verilerinin Hazırlanması

Bu çalışmada sabit yörüngeli MSG programındaki uyduların taşıdığı SEVIRI algılayıcısının görüntüleri kullanılmıştır. MSG programında Meteosat 8,9 ve 10 uyduları bulunmaktadır. Çalışma zaman dilimi (2013-2015) için EUMETSAT arşivinden günlük 3 saatlik zaman periyodunda (00, 03, 06, ..., 18,

21 saatleri), Türkiye'yi kapsayacak şekilde 34-44⁰ Kuzey enlemleri ile 24-47⁰ Doğu boylamları arasında kalan alanın SEVIRI Level 1.5 verisi alınmıştır.

Çalışma dönemi için aktif olan uydu Meteosat 10 uydusudur ve gelen verilerin tamamına yakını bu uydudan alınmıştır. Meteosat 10 uydusunun kayıtlarında eksik olması durumunda Meteosat 8 ve 9 uydularının kayıtlarıyla tamamlanmaktadır. Çalışmada Meteosat 10 verisinde çok az eksik bulunması nedeniyle diğer uydulardan gelen veriler kullanılmamıştır ve böylece veride homojenlik sağlanmıştır. Alınan üç yıllık veri 8993 h5 dosyasından oluşmaktadır ve bunun 8357 tanesi Meteosat 10 uydusuna aittir. Bu h5 dosyaları görüntü işleme adına ihtiyaç duyulan bilgileri de içerisinde bulundurmaktadır. Örnek bir h5 dosyasının içeriği Şekil 4.4'te verilmiştir.




Şekil 4.4. SEVIRI h5 dosyasının içeriği

Alınan her bir h5 dosyası içerisinde de SEVIRI algılayıcısına ait 10 tane kanal verisi bulunmaktadır. Bu 10 kanaldan üçü solar, yedi tanesi ise termal kanaldır. Başka bir ifadeyle üç tane yansıma, yedi tane parlaklık sıcaklığı verisi bulunmaktadır. SEVIRI 4. kanalı gece ve gündüz kayıt yapabilen özel bir kanal olup diğer kanallara görece gürültünün fazla olması nedeniyle ve 12. kanal ise geniş band olması sebebiyle kullanımı tercih edilmemiştir. Solar kanal verileri ise kullanılmak üzere alınmasına rağmen işlemler sırasında güneş zenit açısı kaynaklı hatalı piksel değerlerinin olması nedeniyle kullanılmayıp çalışmada sabit yörüngeli uydu verilerinden sadece termal kanalların parlaklık sıcaklığı verisi ile çalışılmıştır. Çalışmada kullanılan kanallara ait bilgiler ise Çizelge 4.2’de verilmiştir.


Çizelge 4.2. Çalışmada kullanılan SEVIRI kanalları

Kanal Numarası	Kanal İsimleri	Merkez Dalga Boyu (μm)	Öncelikli Uygulama Alanı
5	WV6.2	6.25	Su buharı, yüksek bulutlar, atmosferik kararsızlık
6	WV7.3	7.35	Su buharı, atmosferik kararsızlık
7	IR8.7	8.70	Yeryüzü, bulutlar, atmosferik kararsızlık
8	IR9.7	9.66	Ozon gazı
9	IR10.8	10.80	Yeryüzü, bulutlar, rüzgar vektörleri, kararsızlık
10	IR12.0	12.00	Yeryüzü, bulutlar, atmosferik kararsızlık
11	IR13.4	13.40	Sirrus bulut yüksekliği, atmosferik kararsızlık


Şekil 4.5, Şekil 4.6 ve Şekil 4.7’de 22-06-2013 tarihli ve saat 09.00’a (UTC) ait SEVIRI Level 1.5 ham görüntüleri verilmiştir. Şekil 4.5 yukarıdan aşağıya doğru 5, 6 ve 7. kanalların, Şekil 4.6’da yukarıdan aşağıya doğru 8, 9 ve 10. kanalların, Şekil 4.7 ise 11. kanalın radyans değerleridir. Bu görüntüler EUMETSAT arşivinden alınan ve henüz hiçbir işlemin uygulanmadığı 10 bitlik 0-1023 aralığına ölçeklendirilmiş radyans verileridir.



Şekil 4.5. SEVIRI 5, 6 ve 7. kanallara ait 10-bit ham radyans görüntüleri



Şekil 4.6. SEVIRI 8, 9 ve 10. kanallara ait 10-bit ham radyans görüntüleri



Şekil 4.7. SEVIRI 11. kanala ait 10-bit ham radyans görüntüsü


Türkiye için gün doğumu ve gün batımı saatleri dikkate alınarak, görüntülerden gece verileri elenmiş ve günde 2 ya da 3 görüntü olmak üzere bu gündüz verileriyle çalışılmıştır. Gün doğumu için 35. Enlem ve 25. Boylamın kesişim noktası dikkate alınmış, gün batımı için ise 35. Enlem ile 46. Boylamın kesişim noktası kullanılmıştır. Bu noktalar güneş ile son aydınlanan ve ilk kararın noktalarıdır. SEVIRI Level 1.5 verileri 0 ile 1023 aralığında sayısal değerlerden oluşan 10 bitlik bir radyans görüntüsüdür. Bu görüntüler öncelikle lineer bir eşitlik ile (eşitlik 3.6) radyans bilgisine dönüştürülmüştür. Her bir h5 dosyası içindeki 10 kanala ait radyans verisinden ise yansıtma ve parlaklık sıcaklığı 3 saatlik gündüz verileri için hesaplanarak görüntüler üretilmiştir.

Radyans bilgisinden yansıtma ve parlaklık sıcaklığı verileri iki farklı yöntem ile hesaplanmaktadır. Solar kanallardan (1, 2, ve 3. kanal) yansıtma, termal kanallardan ise parlaklık sıcaklığı türetilmektedir. Her bir kanal için yansıtma ve parlaklık sıcaklığını elde etmek için uydu veri sağlayıcısının verdiği metotlar uygulanmıştır. Öncelikle sayı (Count) olan piksel değerleri eşitlik 3.6 ile radyans değerlerine dönüştürülmüştür. Eşitlik 3.6'daki g ile b sabitleri her bir uydu ve kanal için farklı değerler olup bu bilgiler h5 dosyası içerisinde bulunmaktadır. Eşitlik 3.6'nın tüm h5 dosyalarına uygulanması ile sayıdan radyans değerleri bütün kanal

görüntülerindeki her bir piksel için hesaplanmıştır. Radyansın hesaplanmasıyla yansıtma ve parlaklık sıcaklığının bu değerden hesaplama aşamasına geçilmiştir. Yansıtma ρ^{15} olmak üzere görüntüdeki herhangi bir piksel için eşitlik 3.7 kullanılarak hesaplanmıştır. Eşitlik 3.7'deki c_i , birinci kanal için $c_1 = 20.76$, ikinci kanal için $c_2 = 23.24$ ve üçüncü kana için $c_3 = 19.85$ olarak verilmiştir.

EUMETSAT tarafından SEVIRI radyans verisinden termal kanallar için parlaklık sıcaklığını türetmek amacıyla ters Planck fonksiyonu (eşitlik 3.9) kullanılmış fakat bu yöntemin birkaç $^{\circ}\text{K}$ (Kelvin) hatalı sonuçlar verdiği belirtilmiştir. Bu olumsuzluğu gidermek için her bir radyans değerine karşılık gelen parlaklık sıcaklığı belirlenerek tablo halinde her bir uydu ve kanal için kullanıcılara sunulmuştur. Bu dönüşüm tablosu, bütün uydu ve kanallar için 100 ile 350 $^{\circ}\text{K}$ arasında değerlerden oluşmaktadır. Kanalların minimum radyans değerleri 100 $^{\circ}\text{K}$, maksimum radyans değerleri 350 $^{\circ}\text{K}$ olarak ve diğer ara değerler ise 100 ile 350 $^{\circ}\text{K}$ arasında değişecek şekilde belirlenmiştir. Bu çalışmada da bu tablolar kullanılarak parlaklık sıcaklığı elde edilmiştir.


Üç saatlik gündüz verileri için yansıtma ve parlaklık sıcaklığı hesaplanarak 35-43 $^{\circ}$ Kuzey enlemleri ile 25-46 $^{\circ}$ Doğu boylamlarını kapsayacak şekilde kesilip, 1.8x1.8 km 2 yersel çözünürlükte koordinatlandırılarak geotiff dosya formatında görüntüler üretilmiştir. Bu üç saatlik yansıtma ve parlaklık sıcaklığı verilerinden de günlük ortalama görüntüler yine geotiff dosya formatında oluşturulmuştur. Aylık tahminde kullanmak için ise günlük değerlerden aylık ortalama değerler türetilmiştir. Günlük ve aylık tahmin modellerinin eğitim ve test aşamalarında kullanılacak veri setlerini oluşturmak için, yer istasyonlarının konumuna karşılık gelen kanalların piksel değerleri görüntülerden okunarak dosyalara yazdırılmıştır.




Şekil 4.8. SEVIRI algılayıcısının 5, 6, ve 7. kanallarının koordinatlandırılmış parlaklık sıcaklığı görüntüleri

Şekil 4.8, Şekil 4.9 ve Şekil 4.10'da üretilen parlaklık sıcaklığı görüntülerine örnek verilmiştir. Bu veriler 22-06-2013 tarih ve saat 09.00'a (UTC, Universal Time Coordinate) ait görüntülerdir. Şekil 4.8'de yukarıdan aşağıya doğru 5, 6 ve 7. kanalların, Şekil 4.9'da 8, 9 ve 10. kanalların, Şekil 10'da is 11. kanalın

görüntüsü verilmiştir. Bu görüntülerdeki değerler $^{\circ}\text{K}$ cinsinden sıcaklığı ifade etmektedir. Görüntüler 1.8 km çözünürlüğünde, $35\text{-}43^{\circ}$ Kuzey enlemleri ile $25\text{-}46^{\circ}$ Doğu boylamları arasını kapsayan koordinatlandırılmış verilerdir.



Şekil 4.9. SEVIRI algılayıcısının 8, 9, ve 10. kanallarının koordinatlandırılmış parlaklık sıcaklığı görüntüleri



Şekil 4.10. SEVIRI algılayıcısının 11. kanallının koordinatlandırılmış parlaklık sıcaklığı görüntüsü

4.3. Kutupsal Yörüngeli Uydu Verilerinin Hazırlanması

Bu çalışmada kullanılan verilerden biri de kutupsal yörüngeli Suomi-NPP uydusundaki VIIRS algılayıcısının verileridir. VIIRS algılayıcısının SDR (Sensor Data Records) kod adıyla gruplandırılmış ve içerisinde radyans ($Wm^{-2}sr^{-1}\mu m^{-1}$), ile yansıtma (reflectance) değerlerini bulunduran dokuz solar kanalına ait verilerden yansıtma verisi kullanılmıştır. Kullanılan kanalların bilgileri Çizelge 4.3'te verilmiştir. Bu algılayıcıya ait 2013 ve 2014 verileri NOAA CLASS arşivinden, 2015 verileri ise PEATE sunucusundan alınmıştır.

Algılayıcının her bir kanalının verisi ayrı h5 dosyalarında ve bunlara ek olarak her kayıt için bir konumlandırma (Geolocation) dosyası ayrı h5 dosya formatında indirilmiştir. Türkiye'nin tam bir görüntüsünü elde etmek için uydunun gün içinde farklı geçişlerindeki görüntüler alınmıştır. Verinin elde edilmesinden sonra POLAR2GRID yazılımı ile bu görüntüler koordinatlandırılıp (Georeferencing) birleştirilerek (Mosaic) $600 \times 600 \text{ m}^2$ ($0.0057^0 \times 0.0057^0$) yersel çözünürlükte dosyalar üretilmiştir. Bu dosyalar $35-43^0$ Kuzey enlemleri ile $25-46^0$ Doğu boylamlarını kapsayacak şekilde kesilmiş ve günlük geotiff dosyaları olarak hazırlanmıştır. Üretilen bu günlük yansıma dosyalarından aylık tahminde kullanılmak üzere aylık ortalama yansıtma değerleri türetilmiştir.


Çizelge 4.3. Çalışmada kullanılan VIIRS kanalları

VIIRS Kanal isimleri	Merkez Dalga boyu (µm)	Öncelikli uygulama alanı
M02	0.445	Okyanus, Aerosol
M04	0.555	Okyanus, Aerosol
M05	0.672	Okyanus, Aerosol
M06	0.746	Atmosferik düzeltme
M07	0.865	Okyanus, Aerosol
M08	1.240	Bulut parçacık boyutu
M09	1.378	Sirrus bulut örtüsü
M10	1.610	Kar örtüsü
M11	2.250	Bulutlar

Alınan dosyalardaki yansıtma değerleri 16 bit işaretli sayı (unsigned integer) tipinde yazılmıştır. Bu değerleri POLAR2GRID yazılımı Eşitlik 4.1. ile yansıtma değerine dönüştürmektedir. Eşitlikte r yansıtma, C piksel değerleri ve s ile b sabit katsayılarıdır. Bu katsayılar her bir uydu kanalı için farklıdır ve bu değerler h5 dosyaları içinde mevcuttur.

$$r = s * C + b \quad (4.1)$$

Oluşturulan günlük ve aylık geotiff dosyalarından, çalışılan istasyonların konumuna karşılık gelen piksel değerleri dosyalara yazdırılmıştır. Böylece kutupsal yörüngeli uydu verilerinin hazırlanması da tamamlanmıştır. Bunda sonraki aşamada bütün verilerin birlikte kullanımı için yer, coğrafik, sabit yörünge ve kutupsal yörüngeli veriler birleştirilerek hem günlük hem de aylık tahminde kullanmak üzere modeller için iki adet veri seti üretilmiştir. Şekil 4.11 ve Şekil 4.12'de günlük yansıtma değerlerini içeren örnek VIIRS görüntüleri verilmiştir.



Şekil 4.11. VIIRS kanallarının yansıtma görüntüleri

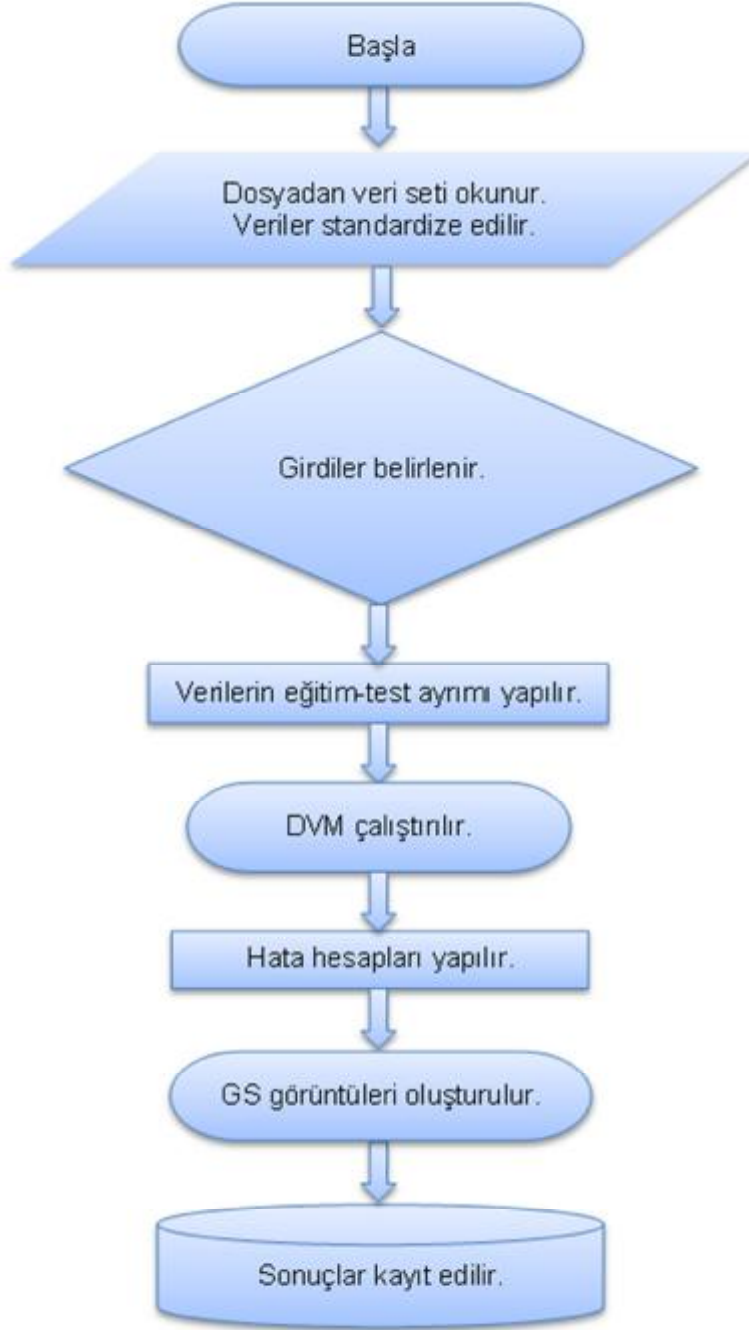
Şekil 4.11’de üretilen günlük yansıtma değerlerini içeren 12-07-2013 tarihli örnek görüntüler verilmiştir. Bu görüntüler yukarıdan aşağıya doğru m02, m04 ve m05 kanallarına aittir. Şekil 4.12’de ise 12-07-2013 tarihli m05, m04 ve m02 kanallarından elde edilen RGB görüntüsü verilmiştir.



Şekil 4.12. VIIRS RGB görüntüsü

4.4. Modelin Oluşturulması

Günlük ve aylık GS'ni yüksek doğrulukla tahmin etmek amacıyla son dönemlerin popüler makine öğrenme algoritmalarından DVM'nin kullanımı tercih edilmiştir. Hem günlük tahmin hem de aylık tahmin için kullanılan modellerin akış diyagramı Şekil 4.13'te verilmiştir. GS'ni etkileyebileceği öngörülen parametrelerden günlük ve aylık veri setleri oluşturulmuştur. Modelimiz bu veri setlerini okuyarak başlamaktadır. Veri setlerine ilk yapılan işlem girdilerin standardize edilerek modelin daha etkin çalışması sağlanmaktadır. Ayrıca yapılan standartlaştırma işlemi veri seti içerisinde bulunabilecek aykırı değerlerin olumsuz etkisini gidermektedir. Sonraki aşamada günlük tahmin için 27, aylık tahmin için 26 adet nitelik içerisinde en uygun girdiler yinelemeli öznelik eleme algoritmasıyla belirlenmektedir. Önemsiz özelliklerin veri setinden çıkarılmasından sonra veri setleri %70 eğitim aşamasında ve %30 test aşamasında kullanılmak üzere ikiye ayrılmaktadır. Bu aşamada DVM için fonksiyonların parametreleri ve uygun fonksiyon araştırılmıştır. Modeller için uygun çekirdek fonksiyonu RBF olarak tespit edilmiştir (Kaba ve ark, 2016). Uygun parametrelerle DVM tahminler yapmakta ve bu tahminlerin sonuçları için hata hesapları yapılmaktadır. Son adımda model görüntülerle çalışarak bütün pikseller için GS'ni tahmin edip sonuçlar kayıt edilmektedir.



Şekil 4.13. Oluşturulan modellerin iş akışı

Makine öğrenme algoritmalarının etkin ve yüksek doğrulukta çalışması için veriye uygulanan ön işlemlerden biri de standardizasyondur. Standardizasyon ile farklı birim ve ölçekteki nitelikler aynı boyuta taşınır. Modeller için her bir niteliğin ortalaması sıfır ve varyansı bir olacak şekilde girdilere standardizasyon yapılmıştır. Modelin başarısını etkileyen bir diğer etken girdiler ve girdi sayısıdır. Günlük ve aylık tahmin için en uygun nitelikler ve girdi sayıları yinelemeli özellik eleme algoritması ile belirlenmiştir. En iyi girdi seti belirlenirken Python Programlama Dilinin sklearn kütüphanesinin RFE (Recursive Feature Elimination) fonksiyonu kullanılmıştır. Bu fonksiyon parametre olarak lineer DVM kullanılmaktadır. Burada DVM için lineer çekirdek fonksiyonu ve ceza parametresi $C = 1.5$ değeri kullanılmıştır Günlük ve aylık tahmin yapan modeller girdi sayısında ve girdi tiplerinde değişiklik göstermektedir.

Tahminlerin doğruluğunu etkileyen bir başka etken kullanılacak fonksiyon ve o fonksiyonun parametreleridir. DVM için RBF, polinom, lineer ve sigmoid fonksiyonları içerisinde en uygun olanı RBF olarak bulunmuştur. Bu aşamada RBF fonksiyonunun serbest parametresi gama (γ) ve DVM ceza faktörü (C) için uygun değerler araştırılmıştır. Hem günlük hem de aylık tahmin için aynı γ ve farklı C değerleri bulunmuştur. Çalışmada fonksiyonların diğer parametreleri varsayılan değerlerinde bırakılmıştır.

Ön işlemlerin tamamlanmasından sonra modelin eğitilip test edilmesine geçilmiştir. Eğitim aşamasında model girdileri ve çıktıyı kullanarak öğrenme yapmakta ve test aşamasında yeni girdilerle sonuçlar üretmektedir. Eğitim aşamasında model üretilen hedef veriyi gördüğünden sonuçlar bu kısımda gerçek değerlerle daha tutarlıdır. Test aşamasında ise eğitim bölümünde öğrenilen örneklerin yanı sıra yeni numunelerle değerler üretilmekte ve sonuçların doğruluğu genelde eğitim aşamasına göre biraz daha düşük çıkmaktadır. Modellerin hem eğitim hem de test sonuçları istatistiksel göstergeler kullanılarak değerlendirilmiştir. Son aşamada tüm Türkiye'yi kapsayacak şekilde bütün pikseller için günlük ve aylık GS tahmin edilerek GS haritaları üretilmiştir.


4.4.1. Günlük Güneşlenme Süresi

GS'nin tahmini için günlük veri seti içerisindeki 27 adet nitelik önem sırasına göre sıralanmıştır. Bu sıralı parametrelerden en önemli 11 tanesi seçilmiş ve sıralı parametreler içinde önemli sırada bulunmamasına rağmen, modelin hata değerlerini iyileştirdiği ve bir pikseli tanımlayan bilgi olduğu için enlem boylam parametreleri de modele girdi olarak eklenmiştir. Böylece günlük değerlerin tahmini için en başarılı modelin girdi sayısı 13 olarak belirlenmiştir. Bu girdiler önem sırasına göre Çizelge 4.4'te verilmiştir. Belirlenen girdiler ile γ ve C parametreleri araştırılarak en iyi günlük tahmin için $\gamma = 0.8$ ve $C = 1.5$ olarak bulunmuş ve $\varepsilon = 0.1$ değeri ile fonksiyonda kullanılmıştır. Bulunan bu parametreler ile günlük model eğitilerek test edilmiştir. İşlemler sonucunda karar fonksiyonundaki b (bias) sabiti 4.4123 olarak bulunmuştur.

Çizelge 4.4. Günlük modelin girdi parametreleri


Önem Sırası	Girdi İsmi	Önem Sırası	Girdi İsmi
1	SEVIRI 7. Kanal	8	VIIRS 7. Kanal
2	SEVIRI 9. Kanal	9	VIIRS 8. Kanal
3	SEVIRI 10. Kanal	10	VIIRS 5. Kanal
4	SEVIRI 11. Kanal	11	Ay
5	Atmosfer Dışı Güneş Işınımı	12	Boylam
6	Deklinasyon Açısı	13	Enlem
7	VIIRS 4. Kanal		

Şekil 4.14'te üstteki grafik eğitim sonuçlarını, alttaki grafik ise test sonuçlarını göstermektedir. Yatay eksen veri sayısını düşey eksen ise GS'ni ifade etmektedir. Grafiklerdeki mavi kesikli çizgiler yer istasyonlarında ölçülen GS değerleri, kırmızı kesikli çizgiler ise yapılan tahminlerin değerleridir. Bu grafikler günlük veri setindeki numunelerden üretilen ilk 400 değeri göstermektedir.




Şekil 4.14. Günlük modelin eğitim ve test aşamalarının simülasyonu

Şekil 4.15'te günlük modelin dağılım grafikleri verilmiştir. Soldaki grafik eğitim sonuçlarını, sağdaki grafik test sonuçlarını göstermektedir. Grafiklerde yatay eksenler yer ölçümlerine, dikey eksenler ise yapılan tahmin değerlerine karşılık gelmektedir. Bu grafiklerde veri dağılımına uygulanan doğru ve denklemi ile belirleme katsayısı R^2 verilmiştir. Eğitim aşaması için $R^2 = 0.8059$ ve test aşaması için $R^2 = 0.7572$ olarak bulunmuştur.



Şekil 4.15. Günlük modelin eğitim ve test aşamalarının dağılım grafikleri


Şekil 4.16’da günlük modeli değerlendirmek için eğitim veri seti kullanılarak üretilen örnek bir öğrenme eğrisi verilmiştir. Grafikte dikey eksen RMSE değerleri ve yatay eksen örnek sayısıdır. Mavi eğri eğitim aşamasındaki hatayı, kırmızı eğri ise test aşamasındaki hatayı ifade etmektedir. Öğrenme eğrisinde modelin başarısı bias ve varyans ile değerlendirilmektedir. Eğrilerin arasındaki mesafe varyansın ve eğrilerin birbirine yakınsadığı değer ise bias’ın ölçüsüdür. Eğitim ve test hata eğrilerinin değişimi incelendiğinde bias ve varyansın biraz yüksek olduğu ve dolayısıyla hatalarında biraz yüksek olduğu görülür. Çizelge 4.5’te ise günlük modelin başarısını değerlendirmek için yapılan hata hesaplarının sonuçları verilmiştir.



Şekil 4.16. Günlük modelin öğrenme eğrisi

Çizelge 4.5. Günlük modelin istatistiksel sonuçları


	MBE	MAE	RMSE	MAPE	%RMSE	R ²
Eğitim	-0.2340	1.0801	1.9067	---	---	0.8059
Test	-0.2337	1.3427	2.1282	---	---	0.7572



Şekil 4.17. 01-01-2015 tarihli yansımaya, parlaklık sıcaklığı ve günlük güneşlenme süresi görüntüleri

Şekil 4.17’de neredeyse tamamen bulutlu olan 01-01-2015 tarihli uydu görüntüsü ve üretilen örnek bir günlük GS haritası verilmiştir. Üstteki görüntü VIIRS 4. kanalına ait yansımaya değerleri ve alttaki harita ise günlük GS değerleridir. VIIRS görüntüsünde koyu renkli kısımlar araziye, parlak yerler ise bulutu ifade etmektedir. GS haritasında minimum GS 1.2138, maksimum GS 11.2495 ve ortalama GS 5.4627 saat değerindedir. GS haritası VIIRS görüntüsü ile ters ilişkili olacaktır. Yani yüksek yansımaya olan yerlerde düşük güneşlenme, düşük yansımaya değerli piksellerde yüksek güneşlenme olacaktır. VIIRS görüntüsünde Bulgaristan

(görüntüde sol üst köşe) ve güney bölgemiz (görüntüde alt kısımlar) bulutsuz, ege bölgesi ve Van gölü çevresinin parçalı bulutlu olması GS haritasına da yansımıştır. Bu iki görüntü birlikte incelendiğinde bulutsuz veya kümülüs türü bulutların bulunduğu bölgelerin yüksek güneşlenme değerlerine sahip olduğu ve tamamen bulutlu piksellerin ise düşük güneşlenmeye sahip olduğu görülür.



Şekil 4.18. 18-07-2015 tarihli yansımaya, parlaklık sıcaklığı ve günlük güneşlenme süresi görüntüleri

Şekil 4.18’de neredeyse tamamen bulutsuz olan 18-07-2015 tarihli uydu görüntüsü ve üretilen GS haritası verilmiştir. Üstteki görüntü VIIRS 4. kanal verisi

ve alttaki görüntü günlük GS'dir. GS haritasında minimum GS 0.9079, maksimum GS 10.7488 ve ortalama GS 6.1068 saat değerindedir. Haritada Ege, iç Anadolu ve Akdeniz bölgesi yüksek güneşlenme değerlerine sahip iken Türkiye'nin doğusu ve Karadeniz kıyıları düşük güneşlenme değerlerine sahiptir. VIIRS kanal görüntüsü incelendiğinde Karadeniz kıyıları ve doğu bölgemizin bulutlu olduğu ve bu bölgeler için GS haritasındaki düşük değerler üretildiği görülebilir. Ayrıca Marmara denizinin doğusundaki bulutlanma gibi çok küçük bulut etkileri de GS haritasına yansımıştır. Güneydoğu bölgemiz bulutsuz ve yüksek sıcaklık değerine sahip olmasına rağmen üretilen GS değerleri bu bölge için düşük kalmıştır. Genel olarak günlük model bulutlu günler için daha iyi sonuç vermektedir.


4.4.2. Aylık Güneşlenme Süresi

Aylık GS'nin tahmini için aylık veri seti içerisindeki 26 parametreden seçilen 10 girdi parametre kullanılmıştır. Aylık modelde de günlük tahminde yapılabilecek benzer şekilde enlem ve boylam sabit tutulup en önemli 8 girdi seçilmiştir. Modelin girdileri önem sırasına göre Çizelge 4.5'te verilmiştir. Bu girdi seti ile γ ve C parametreleri için en uygun değerler araştırılarak $\gamma = 0.8$ ve $C = 3.5$ olarak bulunmuştur. Aylık model için yine $\varepsilon = 0.1$ değeri seçilmiştir. Bu parametreler ile aylık model eğitilerek test edilmiştir. İşlemler sonucunda karar fonksiyonundaki b (bias) 6.7830 olarak bulunmuştur.

Çizelge 4.6. Aylık modelin girdi parametreleri

Önem Sırası	Girdi İsmi	Önem Sırası	Girdi İsmi
1	SEVIRI 7. Kanal	6	VIIRS 4. Kanal"
2	SEVIRI 9. Kanal	7	VIIRS 7. Kanal
3	Atmosfer Dışı Güneş Işınımı	8	VIIRS 8. Kanal
4	VIIRS 2. Kanal	9	Boylam
5	VIIRS 5. Kanal	10	Enlem

Şekil 4.19’de eğitim ve test aşamalarında üretilen aylık tahmin değerlerinin yer ölçümleri ile simülasyonu verilmiştir. Üsteki grafik eğitim sonuçlarını, alttaki grafik ise test sonuçlarını göstermektedir. Yatay eksen veri sayısını düşey eksen ise GS’ni ifade etmektedir. Grafiklerdeki mavi kesikli çizgiler yer istasyonlarında ölçülen GS değerleri, kırmızı kesikli çizgiler ise yapılan tahminlerin değerleridir. Grafikler aylık veri setindeki numunelerden üretilen ilk 410 değeri göstermektedir.

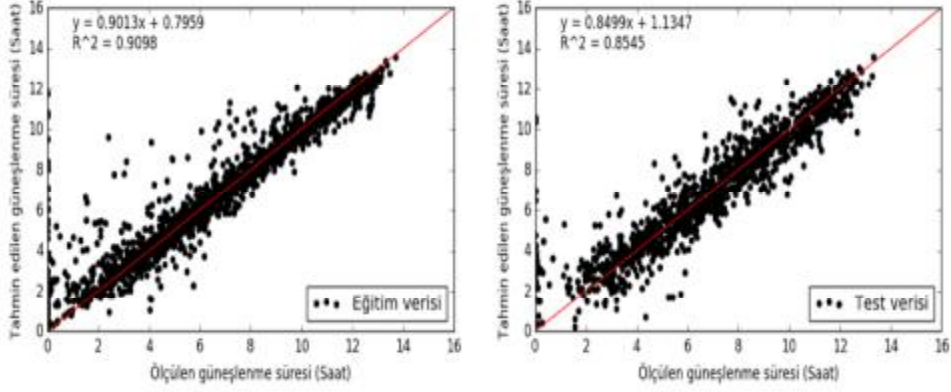


Şekil 4.19. Aylık modelin eğitim ve test aşamalarının simülasyonu

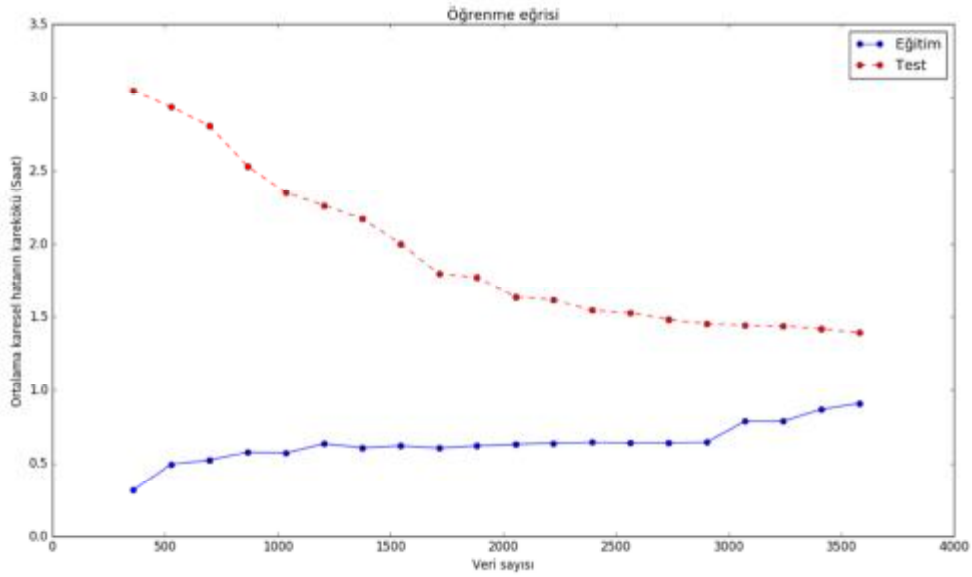
Şekil 4.20’te aylık modelin dağılım grafikleri verilmiştir. Soldaki grafik eğitim sonuçlarını, sağdaki grafik test sonuçlarını göstermektedir. Grafiklerde yatay eksenler yer ölçümlerine, düşey eksenler tahmin değerlerine karşılık gelmektedir. Grafiklerde veri dağılımına uygulanan doğru ve denklemi ile belirleme katsayısı R^2 verilmiştir. Eğitim aşaması için $R^2 = 0.9098$ ve test aşaması için $R^2 = 0.8545$ olarak bulunmuştur.

Şekil 4.21’de aylık modeli değerlendirmek için aylık veri seti kullanılarak üretilen örnek bir öğrenme eğrisi verilmiştir. Grafikte düşey eksen RMSE değerlerini göstermektedir. Mavi eğri eğitim aşamasındaki hatayı, kırmızı eğri ise

test aşamasındaki hatayı ifade etmektedir. Grafikte, test hata eğrisinin ve eğitim hata eğrisinin değişimi incelendiğinde varyansın biraz yüksek olduğu görülür. Çizelge 4.7’de Aylık model için yapılan hata hesaplarının sonuçları verilmiştir.



Şekil 4.20. Aylık modelin eğitim ve test aşamalarının dağılım grafikleri

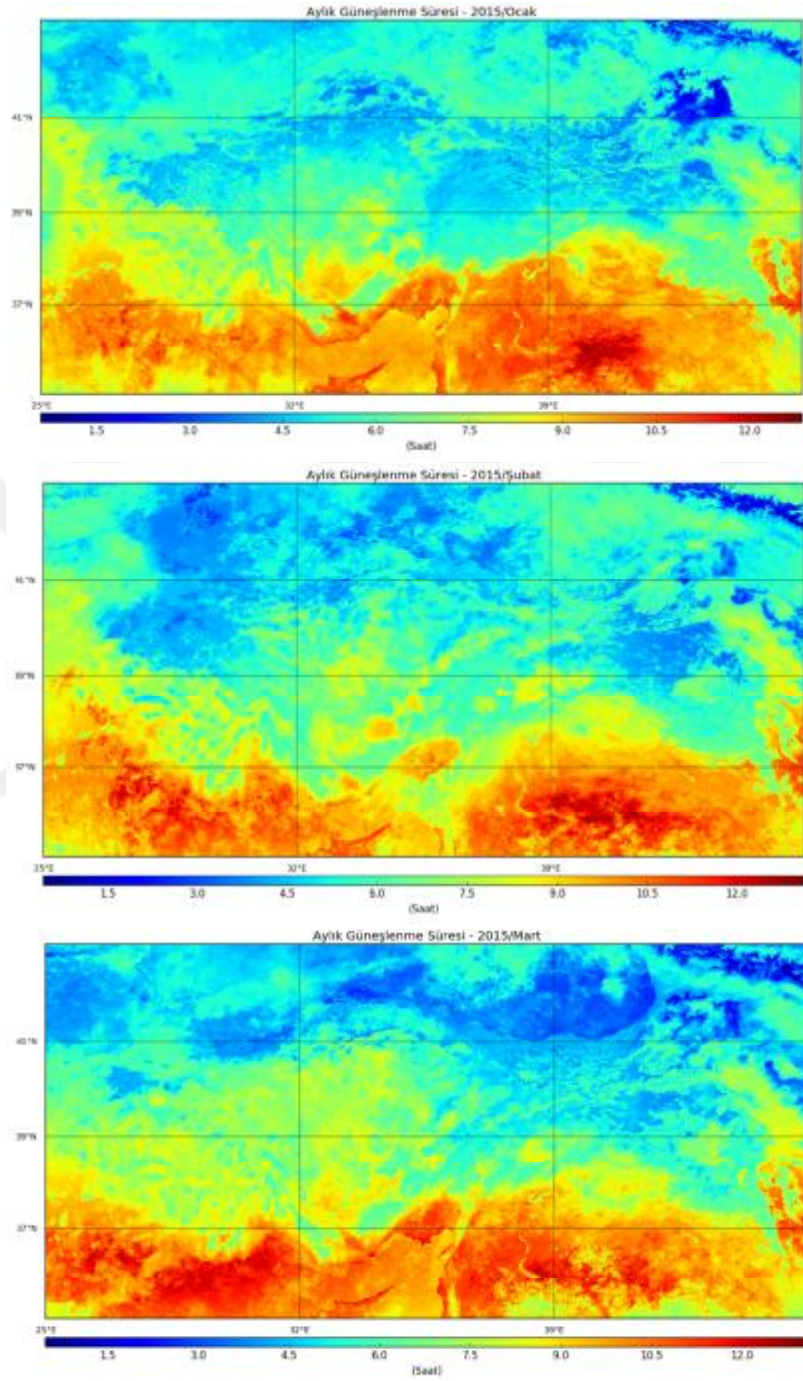


Şekil 4.21. Aylık modelin öğrenme eğrisi

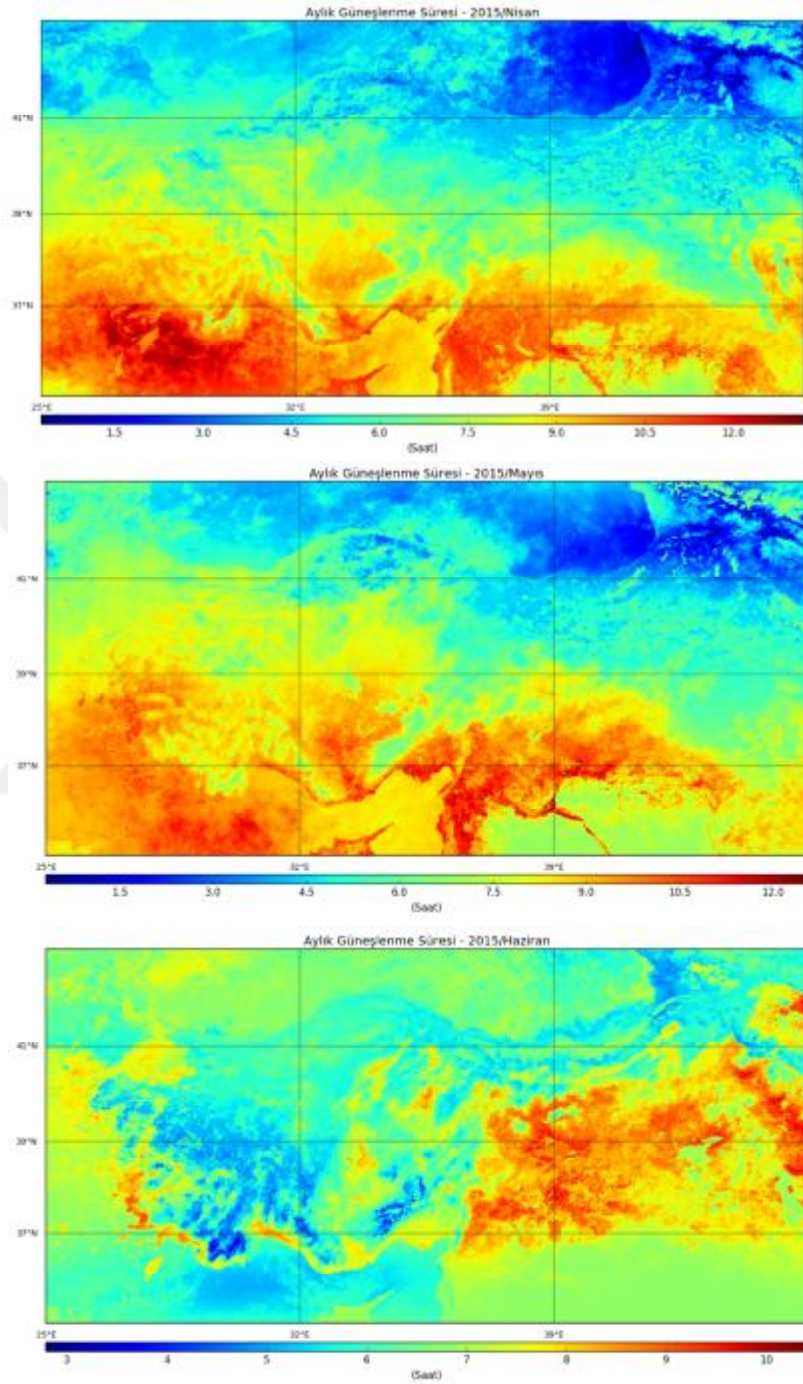
Çizelge 4.7. Aylık modelin istatistiksel sonuçları

	MBE	MAE	RMSE	MAPE	%RMSE	R²
Eğitim	-0.1267	0.3902	0.9172	8.1601	13.5232	0.9098
Test	-0.1103	0.7746	1.1842	16.3647	17.3482	0.8545

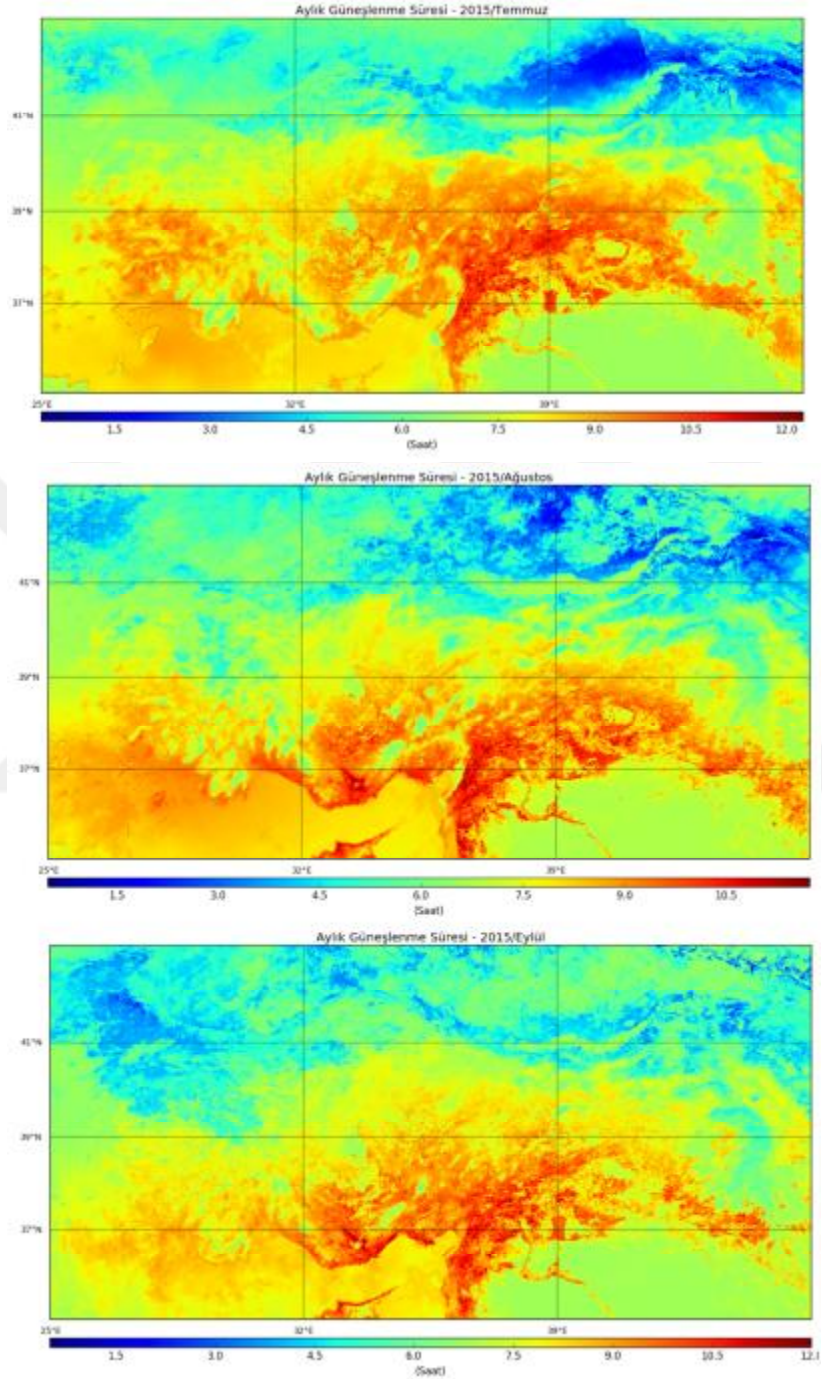
Şekil 4.22'den Şekil 4.25'e 2015 yılının tüm ayları için, aylık model ile üretilen GS haritaları verilmiştir. Ocak ayında GS'nin minimum değeri 0.61, maksimum değeri 12.85, ortalaması 6.91 ve standart sapması da 2.11 olarak bulunmuştur. Mart ayında GS'nin minimum değeri 0.46, maksimum değeri 13.11, ortalaması 6.98 ve standart sapması da 2.37 olarak bulunmuştur. Mayıs ayında GS'nin minimum değeri 0.30, maksimum değeri 12.57, ortalaması 6.94 ve standart sapması da 2.17 olarak bulunmuştur. Temmuz ayında GS'nin minimum değeri 0.35, maksimum değeri 12.26, ortalaması 7.2 ve standart sapması da 1.73 olarak bulunmuştur. Eylül ayında GS'nin minimum değeri 0.50, maksimum değeri 12.00, ortalaması 6.95 ve standart sapması da 1.54 olarak bulunmuştur. Kasım ayında GS'nin minimum değeri 0.18, maksimum değeri 13.21, ortalaması 6.92 ve standart sapması da 2.72 olarak bulunmuştur. Geriye kalan ayların verileri ise yukarıda belirtilen değerler ile benzerdir.



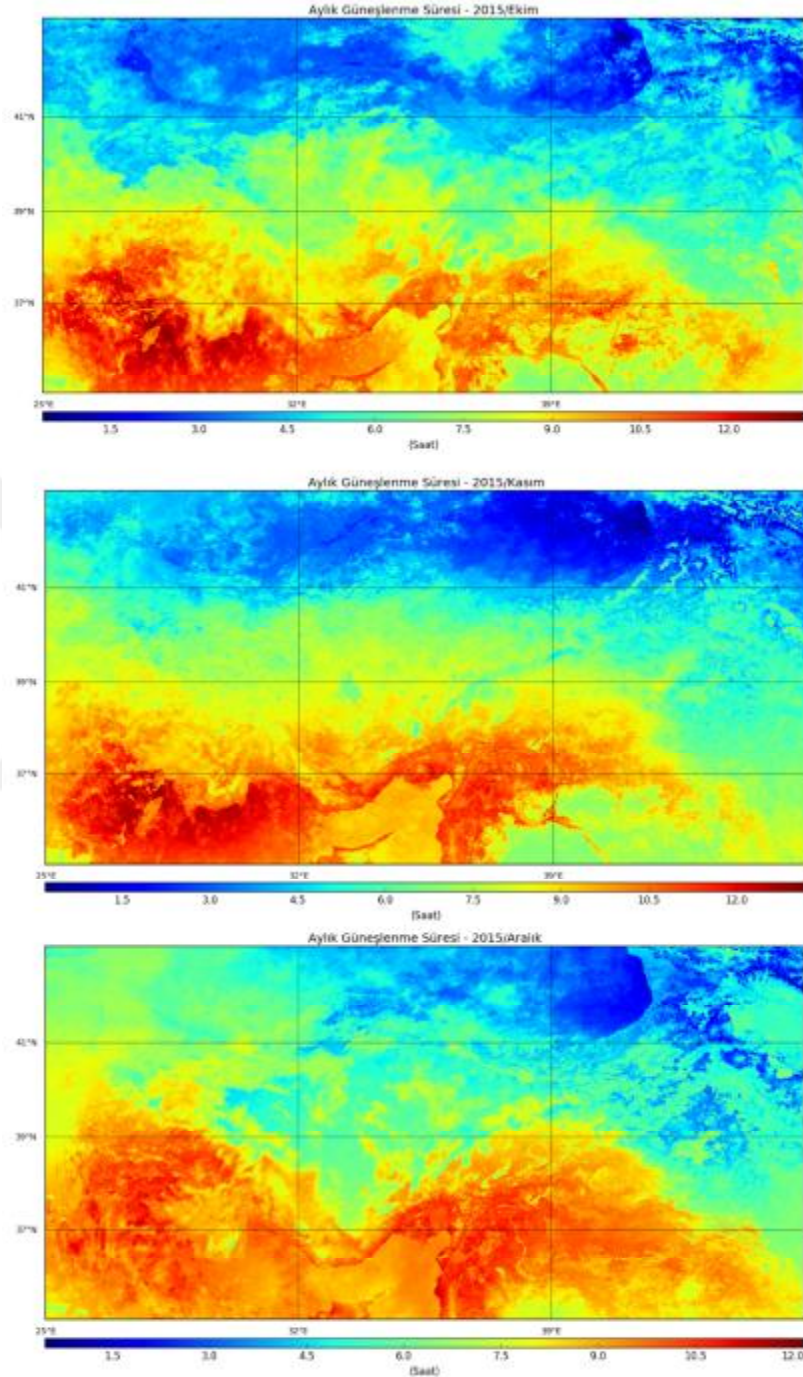
Şekil 4.22. 2015 yılının Ocak, Şubat ve Mart aylarının güneşlenme süreleri



Şekil 4.23. 2015 yılının Nisan, Mayıs ve Haziran aylarının güneşlenme süreleri



Şekil 4.24. 2015 yılının Temmuz, Ağustos ve Eylül aylarının güneşlenme süreleri



Şekil 4.25. 2015 yılının Ekim, Kasım ve Aralık aylarının güneşlenme süreleri

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, Türkiye'nin günlük ve aylık GS değerleri makine öğrenme algoritmalarından DVM yöntemi ile tahmin edilerek 600 metre yersel çözünürlükte GS haritaları oluşturulmuştur. Başarılı tahmin modelleri için uygun fonksiyon ve parametreleri belirlenerek DVM mimarisi geliştirilmiştir. Doğruluğu yüksek tahminler yapmak için yer sabit yörüngeli ve kutupsal yörüngeli uydu verileri ile coğrafik veriler içerisinde en uygun girdiler RFE yöntemiyle belirlenmiştir.

Hem günlük hem de aylık model için SEVIRI algılayıcısının kanal verilerinin coğrafik parametrelerden ve VIIRS verilerinden daha fazla katkı yaptığı tespit edilmiştir. SEVIRI kanallarından yeryüzü ve bulutlar hakkında bilgi veren yedi ve dokuzuncu kanal hem günlük hem de aylık tahminde en önemli ilk iki girdi olmuştur. Günlük tahmin için yeryüzü, bulutlar ve atmosferik kararsızlık hakkında bilgi içeren SEVIRI 10. kanal ve sirus bulutları ile atmosferik kararsızlık hakkında bilgi veren SEVIRI 11. kanal üç ve dördüncü girdiler olmuştur. Hem günlük hem de aylık model için SEVIRI kanal verilerinden sonraki önemli girdi atmosfer dışı güneş ışınımı olmuştur. Coğrafik verilerden deklinasyon açısı günlük model için önemli iken aylık modelde yer almamıştır. VIIRS algılayıcısının öncelikli olarak okyanus ve aerosol konularında uygulama alanı bulan görünür bölge de kayıt yapan dört, beş ve yedinci kanalları ile bulut parçacık boyutu bilgisini veren sekizinci kanal verileri her iki modelde de kullanılır iken mavi dalga boyunda kayıt yapan ikinci kanalı sadece aylık modelde girdi olarak bulunmaktadır. Bu girdilere ek olarak günlük modele ay, enlem ve boylam bilgisi ile aylık modele enlem ve boylam değerleri önem sıralamasında ön planda olmamasına rağmen hata değerlerini düşürerek modellerin başarısını yükselttiği için her iki tahmin modelinin girdilerine de eklenmiştir. Modellerin girdileri incelendiğinde SEVIRI algılayıcısından alınan termal kanal verilerinden dalga boyu büyük olan kanallar GS tahmini için daha önemlidir. VIIRS algılayıcısından alınan solar kanal verilerinden ise görünür bölge ve yakın kızılötesinde kayıt yapan kısa dalga boylu

kanallar GS tahmini için önemli çıkmıştır. Coğrafik verilerde ise çok sayıda parametreye bağlı olarak hesaplanan atmosfer dışı güneş ışımasını GS tahmini için önemli çıkmıştır.

Atmosferdeki su buharı varlığının GS'ni etkileyebileceği öngörüsüyle SEVIRI algılayıcısının su buharı ve yüksek bulut bilgisini barındıran beş ve altıncı kanal verileri çalışmaya dâhil edilmesine karşın bu kanal verileri önemsiz bulunarak veri setlerinden elenmiştir. Atmosferdeki ozan gazı hakkında bilgi veren SEVIRI sekizinci kanalı da GS tahmini için önemsiz bulunarak veri setlerinden elenmiştir. Coğrafik verilerden jülien gün sayısı, güneş saat açısı ve gün uzunluğu modeller için önemsiz bulunmuştur. VIIRS algılayıcısının atmosferik düzeltme için kullanılan altıncı kanalı, sirrus bulutları hakkında bilgi içeren dokuzuncu kanalı, kar bilgisini içeren 10. kanalı ile bulutlar hakkında bilgi veren 11. kanal verileri modeller için önemsiz bulunmuştur.


GS tahmininde, solar kanal verisi olan yansıma değerleri termal kanal verisi olan parlaklık sıcaklığı değerlerine göre daha önemli olduğu literatürde bilinmesine rağmen bu çalışmada SEVIRI termal kanal verileri VIIRS solar kanal verilerinden daha önemli çıkmıştır. VIIRS algılayıcısına ait solar kanal verilerinin alt sırada kalma nedeni VIIRS algılayıcısından günlük tek bir görüntü kullanılmasıdır. Atmosferdeki değişim, yıl boyunca farklılık göstererek yaz ve kış aylarında daha kararlı ve yavaş değişirken bahar aylarında daha hızlı olmaktadır. VIIRS algılayıcısında olduğu gibi, günlük tek bir görüntü kullanıldığında, gün içerisinde havanın hızlı değişimini yakalamak her zaman mümkün olmamaktadır. VIIRS görüntüleri ülkemiz saati ile 10.00 civarını temsil etmektedir. Bu görüntüler gün içerisindeki diğer saatlerde meydana gelen ani değişimleri içermeyebilir. Bu nedenle gün içindeki değişimleri daha doğru temsil eden günlük ortalama SEVIRI verileri model için daha önemli çıkmıştır.

Modellerin sonuçlarını değerlendirmek için literatürde sık kullanılan istatistiksel yöntemlere başvurulmuştur. Günlük modeli değerlendirmek için yapılan hata hesapları incelendiğinde MBE değerleri eğitim aşaması için -0.2340

saat ve test aşaması için -0.2337 saat bulunmuştur. MBE hatasının negatif olması yapılan tahmin değerlerinin genelde ölçüm değerlerinden küçük olmasını ifade eder. Bu durum DVM'nde kullanılan radyal bazlı çekirdek fonksiyonundan kaynaklanmaktadır. Ortalama hatanın büyüklüğünü veren MAE ve RMSE eğitim aşaması için 1.0801 ve 1.9067 saat, test aşaması için ise 1.3427 ve 2.1282 saat olarak bulunmuştur. İki değişken arasındaki ilişkinin büyüklüğünü veren belirleme katsayısı R^2 ise, eğitim aşaması için 0.8059 ve test aşaması için 0.7572 olarak bulunmuştur. Genel olarak günlük tahmin için RMSE değerleri biraz yüksek olmakla beraber sonuçlar bu konuda yapılan çalışmalar ile uyumludur.

Aylık modelin sonuçları incelendiğinde günlük modelde olduğu gibi aylık model için de MBE değerleri negatif bulunmuştur. MAPE ve %RMSE yapılan tahminin hata miktarını yüzde olarak ifade eder ve eğitim aşaması için %8.1601 ve %13.5232 iken test aşaması için %16.3647 ve %17.3482 olarak bulunmuştur. R^2 eğitim aşamasında 0.9098 ve test aşamasında 0.8545 bulunmuştur. Aylık modelin sonuçları literatürdeki çalışmalara göre daha düşük hata oranlarına sahiptir.

Çalışmada 2015 yılının tüm ayları için tahmin yapılarak Türkiye'nin aylık GS haritaları üretilmiştir. Bu aylık haritalardan ise ortalama yıllık GS haritası türetilmiştir. Türkiye'nin 2015 yılı GS haritası Şekil 5.1'de verilmiştir. Harita incelendiğinde, ülkenin güneyi yüksek güneşlenmeye, kuzey bölgesi ise düşük güneşlenme değerlerine sahip olduğu görülür. Güneyden kuzeye doğru GS değerlerinin değişimi interpolasyon sonuçlarından farklı olarak atmosferik etki ile birlikte topografik yapıdaki değişiklikleri de yansıtmaktadır. Güneyde Ege ve Akdeniz kıyıları ile kısmen Güneydoğu Anadolu yüksek GS değerlerine sahiptir. Türkiye'nin orta enlemlerinde ise güney bölgelerinden düşük kuzey bölgelerinden yüksek GS değerleri tahmin edilmiştir. Ayrıca orta enlemlerde GS boylama göre de değişiklik göstermektedir. GS değerlerinin düşük olduğu kuzey bölgemizde ise doğu Karadeniz bölgesi en düşük güneşlenmeye sahip bölgedir. Yıllık GS haritasında minimum GS değeri 2.5311, maksimum GS değeri 10.8024, ortalama değer 6.9492 ve standart sapması 1.7858 saat olarak bulunmuştur.



Şekil 5.1. 2015 yılı Güneşlenme Süresi haritası

Uydu verileri arasında atmosfer, okyanus, buzullar ve yeryüzüne ait bilgi içeren çeşitli ürünler bulunmaktadır. GS ise sadece yer istasyonlarında noktasal olarak ölçülmektedir. Bu çalışmadaki yöntemler kullanılarak GS uydu ürünü olarak kullanıcılara sunulabilir.

Noktasal GS verileri interpolasyon yöntemleri ile yersel süreklilik kazandırılıp farklı çalışmalarda girdi olarak kullanılmaktadır. Bu çalışmada üretilen GS haritaları, interpolasyon ile yapılan haritalarla kıyaslandığında çok daha başarılıdır. İnterpolasyon ürünlerinin yerine bu çalışmanın ürünleri çeşitli çalışmalarda girdi olarak kullanılabilir.

Güneş enerjisini tahmin etmek amacıyla yapılan çalışmalar GS veya bulutluluk bilgisini girdi olarak kullanmışlardır. GS verisini girdi olarak kullanan modellerin daha başarılı olduğu görülmüştür (Muneer ve Gul, 2000). Yere ulaşan güneş enerjisindeki değişim yüzde 70-85'i güneşlenme süreleri ölçümleri ile açıklanabilirken, yüzde 50'si bulutluluk gözlemleri ile açıklanabilmektedir (Bennett, 1969). Bu çalışmada üretilen GS değerleri güneş enerjisi tahmininde girdi veri olarak kullanılabilir gibi enerji verisini girdi olarak kullanan modellerde enerji verisi yerine de kullanılabilir.

Buharlaştırma tarım ve hidroloji gibi bir çok disiplin için krtik bir bilgidir ve GS ile yakından ilişkilidir. GS'nin yüksek olması birçok uygulama için avantaj iken buharlaştırma için olumsuzdur. Özellikle su kaynaklarının sınırlı veya yetersiz olduğu bölgeler için buharlaştırma daha çok önem kazanmaktadır. Kuraklık, sulama ve ürün kurutma gibi çalışmalarda güneşlenme süresi belirleyici bir etkidir ve GS değerlerine göre planlama yapılabilir. Bu çalışmada üretilen GS haritaları tarım ve hidroloji uygulamaları ile ilgili çalışmalarda kullanılabilir.

Ekonomi alanında özellikle turizm ve sağlık gibi konular doğrudan insanı etkiler. Turizmin gelişiminde, planlanmasında bölgelerin GS değerlerine bakılabilir. Sağlık konusunda ise insanların beden ve ruhsal halini GS etkiler ve insan sağlığı ile hastalıklara karşı önlem için GS değerleri dikkate alınabilir. Bu çalışmada üretilen GS haritaları bu uygulamalar için yapılan çalışmalarda girdi veri olarak kullanılabilir.

Yapılan çalışma oldukça iyi sonuçlar üretmesine rağmen aşağıda yapılan öneriler doğrultusunda daha iyi sonuçların alınabileceği öngörülmektedir.

- Türkiye içerisinde daha küçük alt bölgeler ile çalışıldığında modeller daha iyi sonuçlar verebilir.
- Yer sabit yörüngeli uydunun solar kanal verilerinin kullanılmasıyla modellerin doğruluğu yükseltilebilir.
- Solar ve termal kanal görüntüleri her ne kadar bulut bilgisi içerse de modele bulutluluk verisi eklenmesi tahminin başarısını artırabilir.
- Mevsimsel veya havanın bulutla kapalılık seviyesine göre farklı model geliştirilmesi çalışmanın başarısını artırabilir.
- Özellik seçimi için yinelemeli özellik eleme algoritması yerine alternatif boyut azaltma yöntemleri uygulanabilir.
- Farklı makine öğrenme algoritmaları GS konusuna uygulanabilir. Özellikle geliştirilmiş yapay sinir ağları olarak tanımlanan ve GS konusuna

uygulanmamış olan derin öğrenme (Deep Learning) algoritması GS tahmini için kullanılabilir.



KAYNAKLAR

- Akinoglu, B. G., Rusen, S. E., 2013. Combining the satellite imagery with bright sunshine hours: A review. *J Renew Sustain Ener*, 5, 4.
- Aksoy, B., 1999. Analysis of changes in sunshine duration data for Ankara, Turkey. *Theor Appl Climatol*, 64, 3-4, 229-37.
- Al-Alawi, S. M., Al-Hinai, H. A., 1998. An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation. *Renew Energ*, 14, 1-4, 199-204.
- Allen, R. G., Pereira, L. S., Raes, D., Smith, M., 1998. Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. FAO, Rome, 300, 9, D05109.
- Alpaydın, E., 2013. Yapay Öğrenme. 2. Baskı, Boğaziçi Üniversitesi Yayınevi, İstanbul, p. 486.
- Basak, D., Pal, S., Patranabis, D. C., 2007. Support vector regression. *Neural Information Processing-Letters and Reviews*, 11, 10, 203-24.
- Bennett, I., 1969. Correlation of daily insolation with daily total sky cover, opaque sky cover and percentage of possible sunshine. *Sol Energy*, 12, 3, 391-3.
- Bertrand, C., Demain, C., Journee, M., 2013. Estimating daily sunshine duration over Belgium by combination of station and satellite data. *Remote Sens Lett*, 4, 8, 735-44.
- BOM. Bureau of Meteorology, Australia. Erişim tarihi 09.01.2017. Erişim adresi,
http://www.bom.gov.au/qld/townsville/images/Sunshine_650.jpg.

- Ch, S., Sohani, S. K., Kumar, D., Malik, A., Chahar, B. R., Nema, A. K., Panigrahi, B. K., Dhiman, R. C., 2014. A Support Vector Machine-Firefly Algorithm based forecasting model to determine malaria transmission. *Neurocomputing*, 129, 279-88.
- Chapelle, O., Haffner, P., Vapnik, V. N., 1999. Support vector machines for histogram-based image classification. *Ieee T Neural Networ*, 10, 5, 1055-64.
- Chen, J.-L., Liu, H.-B., Wu, W., Xie, D.-T., 2011. Estimation of monthly solar radiation from measured temperatures using support vector machines—a case study. *Renew Energ*, 36, 1, 413-20.
- Cortes, C., Vapnik, V., 1995. Support-Vector Networks. *Mach Learn*, 20, 3, 273-97.
- Devanathan, M., 1975. Weather and the yield of a crop. *Exp Agr*, 11, 03, 183-6.
- Ding, F. L., Sun, L. M., 2015. Prediction of Tobacco Sales Based on Support Vector Machine. *Liss 2014*, 891-6.
- Dolar, M., 2006. Spatial interpolation of sunshine duration in Slovenia. *Meteorol Appl*, 13, 4, 375-84.
- Eissa, Y., Marpu, P. R., Gherboudj, I., Ghedira, H., Ouarda, T. B. M. J., Chiesa, M., 2013. Artificial neural network based model for retrieval of the direct normal, diffuse horizontal and global horizontal irradiances using SEVIRI images. *Sol Energy*, 89, 1-16.
- El-Metwally, M., 2005. Sunshine and global solar radiation estimation at different sites in Egypt. *J Atmos Sol-Terr Phy*, 67, 14, 1331-42.

- Erdi, E., 2015. Güneşlenme Süresinin NWCSAF Bulut Tipi Ürünü Kullanılarak Yapay Sinir Ağları İle Tahmin Edilmesi, Yüksek Lisans Tezi, Adana.
- EUMETSAT, 2013. MSG Level 1.5 Image Data Format Description, Darmstadt, p. 129.
- Fletcher, T., 2009. Support vector machines explained. Tutorial Paper.
- Founda, D., Pierros, F., Sarantopoulos, A., 2017. Evidence of Dimming/Brightening Over Greece from Long-Term Observations of Sunshine Duration and Cloud Cover. In: Perspectives on Atmospheric Sciences. Eds: Springer, p. 753-8.
- Good, E., 2010. Estimating daily sunshine duration over the UK from geostationary satellite data. *Weather*, 65, 12, 324-8.
- Granata, F., Gargano, R., de Marinis, G., 2016. Support Vector Regression for Rainfall-Runoff Modeling in Urban Drainage: A Comparison with the EPA's Storm Water Management Model. *Water*, 8, 3, 69.
- Guyon, I., Elisseeff, A., 2003. An introduction to variable and feature selection. *J Mach Learn Res*, 3, Mar, 1157-82.
- Guyon, I., Weston, J., Barnhill, S., Vapnik, V., 2002. Gene selection for cancer classification using support vector machines. *Mach Learn*, 46, 1-3, 389-422.
- Jain, A., Mehta, R., Mittal, S. K., 2011. Modeling impact of solar radiation on site selection for solar PV power plants in India. *Int J Green Energy*, 8, 4, 486-98.
- Javadi, F., Ahmadi, M. M., Qaderi, K., 2015. Estimation of River Bedform Dimension Using Artificial Neural Network (ANN) and Support Vector Machine (SVM). *J Agr Sci Tech-Iran*, 17, 4, 859-68.

- Kaba, K., Kandirmaz, H., Avci, M., 2016. Estimation of Daily Sunshine Duration Using Support Vector Machines. *Int J Green Energy*, just-accepted.
- Kaiser, D. P., Qian, Y., 2002. Decreasing trends in sunshine duration over China for 1954-1998: Indication of increased haze pollution? *Geophys Res Lett*, 29, 21.
- Kandirmaz, H. M., 2006. A model for the estimation of the daily global sunshine duration from meteorological geostationary satellite data. *Int J Remote Sens*, 27, 22, 5061-71.
- Kandirmaz, H. M., Kaba, K., 2014. Estimation of Daily Sunshine Duration from Terra and Aqua MODIS Data. *Adv Meteorol*.
- Kandirmaz, H. M., Kaba, K., Avci, M., 2014. Estimation of Monthly Sunshine Duration in Turkey Using Artificial Neural Networks. *Int J Photoenergy*.
- Kaytez, F., Taplamacioglu, M. C., Cam, E., Hardalac, F., 2015. Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. *Int J Elec Power*, 67, 431-8.
- Kim, S., Shiri, J., Kisi, O., 2012. Pan evaporation modeling using neural computing approach for different climatic zones. *Water Resour Manag*, 26, 11, 3231-49.
- Kohavi, R., John, G. H., 1997. Wrappers for feature subset selection. *Artificial intelligence*, 97, 1, 273-324.
- Kothe, S., Good, E., Obregon, A., Ahrens, B., Nitsche, H., 2013. Satellite-Based Sunshine Duration for Europe. *Remote Sens-Basel*, 5, 6, 2943-72.

- Matuszko, D., 2012. Influence of cloudiness on sunshine duration. *Int J Climatol*, 32, 10, 1527-36.
- Matuszko, D., 2015. A comparison of sunshine duration records from the Campbell-Stokes sunshine recorder and CSD3 sunshine duration sensor. *Theor Appl Climatol*, 119, 3-4, 401-6.
- Matzarakis, A. P., Katsoulis, V. D., 2006. Sunshine duration hours over the Greek region. *Theor Appl Climatol*, 83, 1-4, 107-20.
- METOFFICE. UK National Meteorological Service. Eriřim tarihi 09.01.2017. Eriřim adresi, <http://www.metoffice.gov.uk/guide/weather/observations-guide/how-we-measure-sunshine>.
- MGM. Meteoroloji Genel M¼d¼rl¼g¼. Eriřim tarihi 09.01.2017. Eriřim adresi, <https://www.mgm.gov.tr/genel/meteorolojikuydular.aspx>.
- Mohandes, M. A., Rehman, S., 2013. Estimation of sunshine duration in Saudi Arabia. *J Renew Sustain Ener*, 5, 3.
- Muneer, T., Gul, M. S., 2000. Evaluation of sunshine and cloud cover based models for generating solar radiation data. *Energ Convers Manage*, 41, 5, 461-82.
- NASA. Polar Orbiting Mission, Suomi-NPP. Eriřim tarihi 09.01.2017. Eriřim adresi, <https://jointmission.gsfc.nasa.gov/suomi.html>.
- NOAA, 2013. Visible Infrared Imaging Radiometer Suite (VIIRS) Sensor Data Record (SDR) User's Guide, NOAA TECHNICAL REPORTS, Washington, D.C., p.
- Olseth, J. A., Skartveit, A., 2001. Solar irradiance, sunshine duration and daylight illuminance derived from METEOSAT data for some European sites. *Theor Appl Climatol*, 69, 3-4, 239-52.

- PIERCECOLLEGE. Pierce College Weather Station. Erişim tarihi 09.01.2017. Erişim adresi, <http://piercecollegeweather.com/wp-content/uploads/2015/03/burnpaper1.jpg>.
- POWERFROMTHESUN. Chapter-3: The Sun's Position. Erişim tarihi 09.01.2017. Erişim adresi, <http://www.powerfromthesun.net/Book/chapter03/Image60.jpg>.
- Rahimikhoob, A., 2014. Estimating sunshine duration from other climatic data by artificial neural network for ET0 estimation in an arid environment. *Theor Appl Climatol*, 118, 1-2, 1-8.
- Robaa, S. M., 2008. Evaluation of sunshine duration from cloud data in Egypt. *Energy*, 33, 5, 785-95.
- Sanchez-Lorenzo, A., Calbo, J., Brunetti, M., Deser, C., 2009. Dimming/brightening over the Iberian Peninsula: Trends in sunshine duration and cloud cover and their relations with atmospheric circulation. *J Geophys Res-Atmos*, 114.
- Sanchez-Lorenzo, A., Calbó, J., Martín-Vide, J., 2008. Spatial and temporal trends in sunshine duration over Western Europe (1938-2004). *J Climate*, 21, 22, 6089-98.
- Sen, Z., 1998. Fuzzy algorithm for estimation of solar irradiation from sunshine duration. *Sol Energy*, 63, 1, 39-49.
- Shamim, M. A., Remesan, R., Han, D. W., Ejaz, N., Elahi, A., 2012. An improved technique for global daily sunshine duration estimation using satellite imagery. *J Zhejiang Univ-Sc A*, 13, 9, 717-22.
- Smola, A. J., Schölkopf, B., 2004. A tutorial on support vector regression. *Statistics and computing*, 14, 3, 199-222.

- Suehrcke, H., Bowden, R. S., Hollands, K. G. T., 2013. Relationship between sunshine duration and solar radiation. *Sol Energy*, 92, 160-71.
- Tehrany, M. S., Pradhan, B., Jebur, M. N., 2014. Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS. *J Hydrol*, 512, 332-43.
- Trnka, M., Zalud, Z., Eitzinger, J., Dubrovsky, M., 2005. Global solar radiation in Central European lowlands estimated by various empirical formulae. *Agr Forest Meteorol*, 131, 1-2, 54-76.
- Unal, Y., Kindap, T., Karaca, M., 2003. Redefining the climate zones of Turkey using cluster analysis. *Int J Climatol*, 23, 9, 1045-55.
- Vapnik, V., 1998. The Support Vector method of function estimation. *Nonlinear Modeling*, 55-85.
- Vapnik, V., Golowich, S. E., Smola, A., 1997. Support vector method for function approximation, regression estimation, and signal processing. *Advances in Neural Information Processing Systems* 9, 9, 281-7.
- Vapnik, V. N., Mukherjee, S., 2000. Support vector method for multivariate density estimation. *Adv Neur In*, 12, 659-65.
- Vivar, M., Fuentes, M., Norton, M., Makrides, G., de Bustamante, I., 2014. Estimation of sunshine duration from the global irradiance measured by a photovoltaic silicon solar cell. *Renew Sust Energ Rev*, 36, 26-33.
- Wild, M., Gilgen, H., Roesch, A., Ohmura, A., Long, C. N., Dutton, E. G., Forgan, B., Kallis, A., Russak, V., Tsvetkov, A., 2005. From

- dimming to brightening: Decadal changes in solar radiation at Earth's surface. *Science*, 308, 5723, 847-50.
- Wu, B., Liu, S., Zhu, W., Yu, M., Yan, N., Xing, Q., 2016. A Method to Estimate Sunshine Duration Using Cloud Classification Data from a Geostationary Meteorological Satellite (FY-2D) over the Heihe River Basin. *Sensors-Basel*, 16, 11, 1859.
- Yadav, A. K., Chandel, S. S., 2014. Solar radiation prediction using Artificial Neural Network techniques: A review. *Renew Sust Energ Rev*, 33, 772-81.
- Yalçın, G., Demircan, M., Ulupınar, Y., Bulut, E., 2005. *Klimatoloji-1*, DMİ Yayınları, Ankara, p. 227.
- Zheng, B. J., Myint, S. W., Thenkabail, P. S., Aggarwal, R. M., 2015. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *Int J Appl Earth Obs*, 34, 103-12.
- Zhu, X. C., Qiu, X. F., Zeng, Y., Gao, J. Q., He, Y. J., 2015. A remote sensing model to estimate sunshine duration in the Ningxia Hui Autonomous Region, China. *J Meteorol Res-Prc*, 29, 1, 144-54.

ÖZGEÇMİŞ

1983'te Kahramanmaraş'ta doğdu. İlk orta ve lise öğrenimini Kahramanmaraş'ta tamamladı. 2008 yılında Mersin Üniversitesi Fen Edebiyat Fakültesi Fizik Bölümünden mezun oldu. 2012 yılında Çukurova Üniversitesi Fen Bilimleri Enstitüsü Fizik Anabilim Dalında yüksek lisans derecesini tamamladı ve aynı yıl Çukurova Üniversitesi Fen Bilimleri Enstitüsü Fizik Anabilim Dalında doktora programına başladı.





EKLER



EK 1**AYLIK TAHMİNDE KULLANILAN MGM İSTASYONLARI**

İK	E (N°)	B (E°)	Y (m)	Şehir	İlçe
17015	41.08	31.17	10	DUZCE	AKCAKOCA
17020	41.6248	32.3569	33	BARTIN	MERKEZ
17022	41.4492	31.7779	135	ZONGULDAK	MERKEZ
17024	41.9789	33.7636	64	KASTAMONU	INEBOLU
17026	42.0299	35.1545	32	SINOP	MERKEZ
17030	41.3435	36.2553	4	SAMSUN	ATAKUM
17033	40.9838	37.8858	5	ORDU	MERKEZ
17040	41.04	40.5013	3	RIZE	MERKEZ
17042	41.4065	41.433	33	ARTVIN	HOPA
17045	41.1752	41.8187	625	ARTVIN	MERKEZ
17046	41.0922	42.7035	1827	ARDAHAN	MERKEZ
17050	41.6767	26.5508	51	EDİRNE	MERKEZ
17052	41.7382	27.2178	232	KIRKLARELİ	MERKEZ
17056	40.9585	27.4965	4	TEKIRDAG	MERKEZ
17059	41.2505	29.0384	38	İSTANBUL	KUMKOY
17065	40.9866	29.2135	123	İSTANBUL	MERKEZ
17066	40.77	29.93	76	KOCAELİ	MERKEZ
17069	40.7676	30.3934	30	SAKARYA	MERKEZ
17072	40.8437	31.1488	146	DUZCE	MERKEZ
17080	40.6086	33.6102	751	CANKIRI	MERKEZ
17084	40.5461	34.9362	776	CORUM	MERKEZ
17085	40.6668	35.8353	409	AMASYA	MERKEZ
17086	40.3312	36.5577	611	TOKAT	MERKEZ
17088	40.4598	39.4653	1216	GUMUSHANE	MERKEZ
17090	39.7437	37.002	1294	SIVAS	MERKEZ
17094	39.7523	39.4868	1216	ERZINCAN	MERKEZ
17097	40.6042	43.1073	1777	KARS	MERKEZ
17099	39.7253	43.0522	1646	AGRI	MERKEZ
17100	39.9227	44.0523	856	IGDIR	MERKEZ

17110	40.191	25.9075	79	CANAKKALE	GOKCEADA
17111	39.8326	26.0728	30	CANAKKALE	BOZCAADA
17112	40.141	26.3993	6	CANAKKALE	MERKEZ
17116	40.2308	29.0133	100	BURSA	OSMANGAZI
17118	40.2552	29.5624	238	BURSA	YENISEHIR
17120	40.1414	29.9772	539	BILECIK	MERKEZ
17129	39.9558	32.6854	806	ANKARA	ETIMESGUT
17130	39.9727	32.8637	891	ANKARA	KECIOREN
17135	39.8433	33.5181	751	KIRIKKALE	MERKEZ
17140	39.8213	34.8095	1301	YOZGAT	MERKEZ
17145	39.5895	27.0191	21	BALIKESIR	EDREMIT
17155	39.4171	29.9891	969	KUTAHYA	MERKEZ
17160	39.1639	34.1561	1007	KIRSEHIR	MERKEZ
17162	39.185	36.0805	1182	SIVAS	GEMEREK
17165	39.1058	39.5408	981	TUNCELI	MERKEZ
17172	38.4693	43.346	1675	VAN	MERKEZ
17175	39.3113	26.6861	4	BALIKESIR	AYVALIK
17180	39.0737	26.888	3	IZMIR	DIKILI
17184	38.9118	27.8233	92	MANISA	AKHISAR
17186	38.6153	27.4049	71	MANISA	MERKEZ
17190	38.738	30.5604	1034	AFYONKARAHISAR	MERKEZ
17191	38.6503	32.9226	969	KONYA	CIHANBEYLI
17192	38.3705	33.9987	970	AKSARAY	MERKEZ
17193	38.6163	34.7025	1260	NEVSEHIR	MERKEZ
17196	38.687	35.5	1094	KAYSERI	MERKEZ
17199	38.3367	38.2173	950	MALATYA	MERKEZ
17203	38.8847	40.5007	1177	BINGOL	MERKEZ
17204	38.7502	41.5017	1322	MUS	MERKEZ
17205	38.5033	42.2808	1687	BITLIS	TATVAN
17210	37.9258	41.9345	895	SIIRT	MERKEZ
17220	38.3949	27.0819	29	IZMIR	MERKEZ
17221	38.3036	26.3724	5	IZMIR	CESME
17227	37.8167	27.8873	32	AYDIN	CILDIR
17232	37.8597	27.2652	25	AYDIN	KUSADASI
17237	37.762	29.0921	425	DENIZLI	MERKEZ

17238	37.722	30.294	957	BURDUR	MERKEZ
17239	38.3688	31.4297	1002	KONYA	AKSEHIR
17240	37.7848	30.5679	997	ISPARTA	MERKEZ
17242	37.6777	31.7463	1141	KONYA	BEYSEHIR
17246	37.1932	33.2202	1018	KARAMAN	MERKEZ
17248	37.5255	34.0485	1046	KONYA	EREGLI
17250	37.9587	34.6795	1195	NIGDE	MERKEZ
17255	37.576	36.915	572	KAHRAMANMARAS	MERKEZ
17261	37.0585	37.351	854	GAZIANTEP	MERKEZ
17262	36.7085	37.1123	640	KILIS	MERKEZ
17265	37.7553	38.2775	672	ADIYAMAN	MERKEZ
17270	37.1608	38.7863	550	SANLIURFA	MERKEZ
17275	37.3063	40.7235	1040	MARDIN	MERKEZ
17282	37.8636	41.1562	610	BATMAN	MERKEZ
17285	37.5745	43.7388	1727	HAKKARI	MERKEZ
17287	37.5209	42.4523	1350	SIRNAK	MERKEZ
17290	37.0328	27.4398	26	MUGLA	BODRUM
17292	37.2095	28.3668	646	MUGLA	MERKEZ
17296	36.6264	29.1239	3	MUGLA	FETHIYE
17297	36.7083	27.6919	28	MUGLA	DATCA
17298	36.8395	28.2452	16	MUGLA	MARMARIS
17310	36.5507	31.9803	6	ANTALYA	ALANYA
17320	36.0678	32.8588	2	MERSIN	ANAMUR
17330	36.382	33.937	10	MERSIN	SILIFKE
17340	36.7752	34.6018	7	MERSIN	YENISEHIR
17351	37.0041	35.3443	23	ADANA	YUREYIR
17355	37.1013	36.2523	94	OSMANIYE	MERKEZ
17370	36.5888	36.1548	4	HATAY	ISKENDERUN
17372	36.2048	36.1513	104	HATAY	ANTAKYA
17375	36.3022	30.1465	2	ANTALYA	FINIKE
17380	36.2002	29.6502	153	ANTALYA	KAS
17602	41.7526	32.3827	73	BARTIN	AMASRA
17614	40.4088	27.06	56	CANAKKALE	BIGA
17624	41.143	37.293	16	ORDU	UNYE
17636	40.9758	28.7865	37	ISTANBUL	MERKEZ

17688	40.3013	41.5378	1576	ERZURUM	TORTUM
17718	39.7728	40.3843	1429	ERZINCAN	TERCAN
17725	39.9698	32.8623	852	ANKARA	KECIOREN
17734	39.3618	38.1142	1121	SIVAS	DIVRIGI
17749	38.4639	27.3705	208	IZMIR	KEMAL PASA
17754	39.0788	33.0657	1005	KONYA	KULU
17760	39.1897	35.2532	1070	YOZGAT	BOGAZLIYAN
17776	38.9597	41.0503	1366	BINGOL	SOLHAN
17780	39.1337	42.5308	1540	MUS	MALAZGIRT
17789	38.6237	27.0433	10	IZMIR	MENEMEN
17802	38.7251	36.3904	1542	KAYSERI	PINARBASI
17806	38.6907	39.926	1000	ELAZIG	PALU
17836	38.3713	35.4745	1204	KAYSERI	DEVELI
17847	38.2541	39.7692	865	DIYARBAKIR	ERGANI
17866	38.024	36.4823	1344	KAHRAMANMARAS	GOKSUN
17906	37.548	34.4867	1453	NIGDE	ULUKISLA
17944	37.3651	38.5134	622	SANLIURFA	BOZOVA
17952	36.7372	29.9125	1095	ANTALYA	ELMALI
17968	36.8406	40.0307	360	SANLIURFA	CEYLANPINAR
17974	36.2715	32.3045	21	ANTALYA	GAZIPASA
17978	36.8898	34.9558	12	MERSIN	TARSUS

EK 2

AYLIK MODELİN PYTHON KODLARI

```
#-----#
import os, time, glob, operator
from collections import OrderedDict
from osgeo import gdal, osr
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import StandardScaler,MinMaxScaler
from sklearn.model_selection import train_test_split, learning_curve
from sklearn.svm import SVR, NuSVR
from sklearn.model_selection import GridSearchCV, learning_curve
from sklearn.feature_selection import RFE
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score
from sklearn.neural_network import MLPRegressor
from sklearn.linear_model import LinearRegression
#####

def find_linear_parameters(inputs, target):

    print ("\nLinear SVR icin en iyi C parametresi belirleniyor..\n")
    t0 = time.time()
    svr = SVR()
    linear_range = {'kernel':['linear'], 'C':[c for c in np.logspace(-5,5,11)]}
    linear_C = GridSearchCV(svr, linear_range, cv=3, verbose=1)
    linear_C.fit(inputs, target)
    best_linear_C = linear_C.best_params_['C']
```

```

t1 = (time.time() - t0) / 60.0
print ("\nC parametresini bulma suresi %4.4f dakika" %t1)
print ("\nEn iyi linear C parametresi: ", best_linear_C,"\n")

return best_linear_C

def find_rbf_parameters(inputs, target):

    print ("\nSVR icin en iyi C parametresi belirleniyor..\n")
    t0 = time.time()
    svr = SVR()
    rbf_range = {'kernel':['rbf'], 'C':[c for c in np.arange(1,10,0.1)],\
                'gamma': [g for g in np.arange(0.1,1, 0.1)]}
    rbf_C_g = GridSearchCV(svr, rbf_range, cv=3, verbose=1)#np.logspace(-
6,6,13)np.arange(1,50,1)
    rbf_C_g.fit(inputs, target)
    best_rbf_C = rbf_C_g.best_params_['C']
    best_rbf_gamma = rbf_C_g.best_params_['gamma']
    t1 = (time.time() - t0) / 60.0
    print ("\nC parametresini bulma suresi %4.4f dakika" %t1)
    print ("\nEn iyi rbf C parametresi: ", best_rbf_C, best_rbf_gamma)

    return best_rbf_C, best_rbf_gamma

#-----#

def find_best_inputs_set(inputs_value, target_value, lin_best_C):

    """print("\nGirdi secimi yapiliyor..")
    linear_svr = SVR(kernel='linear', C=lin_best_C)

```

```

selector = RFE(linear_svr, n_features_to_select=1, step=1)
slctr = selector.fit(inputs_value, target_value)
ordered_input = slctr.ranking_
print ("\nGirdilerin onem sirasi:\n\n", ordered_input)"""

"""ordered_input = [24,27,28, 26,17,23, 18,15,14,3,\
                    4,6,5,32,7,8,11,13,12,9,22,10,\
                    31,21,20,30,29,1,25,2,26,19]"""

ordered_input = [24,27, 2,2,17, 23,18,15,14,3,\
                 4,6,5,32,7,8,11,13,12,9,22,10,\
                 31,21,20,30,29,1,25,2,26,19]

columnIndex = []
for index, item in enumerate(ordered_input):
    if item > 8 : columnIndex.append(index)
    else: pass

new_input_train = np.delete (inputs_value, columnIndex, 1)
print ("\nElenen sutunlar:\n\n", columnIndex)
print ("\nNew-Train-Test: ", new_input_train.shape)

return new_input_train
#-----#

def mlp_regressor(input_train, target_train, input_test):

    mlp = MLPRegressor(hidden_layer_sizes=(31, 14),\
                       activation='tanh',\
                       momentum=0.95, alpha=0.00001, tol=0.00001,\

```



```

        solver='adam', max_iter=2000)#, verbose=True)

mlp.fit(input_train, target_train)
model_train = mlp.predict(input_train)
model_test = mlp.predict(input_test)

print(mlp.n_iter_, "\n", mlp.n_layers_)

return model_train, model_test
#-----#

def mbe(targets, predictions):
    return ((targets - predictions).mean())

def mape(predictions, targets):
    return (np.mean(abs(predictions - targets)/targets))*100

def model_evaluate(y_true, y_prediction):

    MBE = mbe(y_true, y_prediction)
    MAE = mean_absolute_error(y_true, y_prediction)
    MAPE = mape(y_true, y_prediction)
    RMSE = np.sqrt(mean_squared_error(y_true, y_prediction))
    rRMSE = 100.0 * RMSE / np.mean(y_true)
    RKARE = r2_score(y_true, y_prediction)

    print ("MBE\t:",MBE, "\nMAE\t:",MAE, "\nMAPE\t:",MAPE,\
          "\nRMSE\t:",RMSE, "\nrRMSE\t:",rRMSE, "\nRKARE\t:",RKARE)
#-----#

```

```

def line_plots(y_train, pred_train, y_test, pred_test):

    plt.figure(1)

    plt.subplot(211)

    train_x_axis = np.arange(len(y_train))
    plt.plot(train_x_axis, y_train, "b--", label='Ölçüm')
    plt.plot(train_x_axis, pred_train, "r--", label='Tahmin')
    plt.ylabel('Güneşlenme süresi (Saat)')
    plt.title('Eğitim sonuçları')
    plt.legend(loc=1)
    plt.axis([0,410, -1, 16])

    plt.subplot(212)

    test_x_axis = np.arange(len(y_test))
    plt.plot(test_x_axis, y_test, "b--", label='Ölçüm')
    plt.plot(test_x_axis, pred_test, "r--", label='Tahmin')
    plt.xlabel('Veri sayısı')
    plt.ylabel('Güneşlenme süresi (Saat)')
    plt.title('Test sonuçları')
    plt.legend(loc=1)
    plt.axis([0,410, -1, 16])

    plt.show()

def scatter_plots(y_train, pred_train, y_test, pred_test):

```

```
plt.figure(2)
```

```
plt.subplot(221)
```

```
RKARE_train = r2_score(y_train, pred_train)
```

```
linReg = LinearRegression().fit(y_train[np.newaxis].T,  
pred_train[np.newaxis].T)
```

```
a_tr = '{:06.4f}'.format(linReg.coef_[0][0])
```

```
b_tr = '{:06.4f}'.format(linReg.intercept_[0])
```

```
rr_tr = '{:06.4f}'.format(RKARE_train)
```

```
text1 = "y = " + str(a_tr) + "x + " + str(b_tr)
```

```
text2 = "R^2 = " + str(rr_tr)
```

```
plt.subplot(221).text(1, 15, text1)
```

```
plt.subplot(221).text(1, 14, text2)
```

```
plt.scatter(y_train, pred_train, c='k', label="Eğitim verisi")
```

```
plt.xlabel('Ölçülen güneşlenme süresi (Saat)')
```

```
plt.ylabel('Tahmin edilen güneşlenme süresi (Saat)')
```

```
#plt.title('Eğitim verisi')
```

```
plt.legend(loc=4)
```

```
plt.plot([0, 16], [0, 16], 'r-')
```

```
plt.axis([0,16, 0, 16])
```

```
plt.subplot(222)
```

```
RKARE_test = r2_score(y_test, pred_test)
```

```
lr = LinearRegression().fit(y_test[np.newaxis].T, pred_test[np.newaxis].T)
```

```
a_te = '{:06.4f}'.format(lr.coef_[0][0])
```

```
b_te = '{:06.4f}'.format(lr.intercept_[0])
```

```
rr_te = '{:06.4f}'.format(RKARE_test)
```

```

t1 = "y = " + str(a_te) + "x + " + str(b_te)
t2 = "R^2 = " + str(rr_te)
plt.subplot(222).text(1, 15, t1)
plt.subplot(222).text(1, 14, t2)
plt.scatter(y_test, pred_test, c='k', label="Test verisi")
plt.xlabel('Ölçülen güneşlenme süresi (Saat)')
plt.ylabel('Tahmin edilen güneşlenme süresi (Saat)')
#plt.title('Test verisi')
plt.legend(loc=4)
plt.plot([0, 16], [0, 16], 'r-')
plt.axis([0,16, 0, 16])

plt.show()

def sv_plots(input_train, target_train, sv_index):

    plt.figure(3)
    #Bu blok destek vektorlerini ve calisma suresinin grafigini ciziyor..
    plt.subplot(221)
    plt.scatter(input_train[:, 2][sv_index], target_train[sv_index],\
                c='k', label='Destek vektorleri')
    plt.xlabel('train inputs')
    plt.ylabel('train target')
    #plt.legend(loc="upper left")

    plt.subplot(222)
    plt.scatter(input_train[:, 3][sv_index], target_train[sv_index],\
                c='k', label='Destek vektorleri')
    plt.show()

```

```

def my_learning_curve(myFunction, inputs, targets, c, g):

    plt.figure(4)

    train_sizes, train_scores, test_scores = \
        learning_curve(myFunction, inputs, targets,\
                        train_sizes=np.linspace(0.1, 1, 20), cv=10,\
                        scoring = 'neg_mean_squared_error')

    plt.plot(train_sizes, ( - train_scores.mean(1))**0.5, 'o-', color="b",
label="Eğitim")
    plt.plot(train_sizes, ( - test_scores.mean(1))**0.5, 'o--', color="r", label="Test")
    plt.xlabel("Veri sayısı")
    plt.ylabel("Ortalama karesel hatanın karekökü (Saat)")
    plt.title("Öğrenme eğrisi")
    plt.legend(loc="best")

    plt.show()

    """plt.figure(5)
    plt.scatter(model1, inverse_model1, c='k', label='Test verileri')
    plt.xlabel('Normalize güneş radyasyonu')
    plt.ylabel('Ters Normalize Güneş radyasyonu (MJ/m^2/Gün)')
    plt.title('Normalize ve Ters Normalize yapılan güneş radyasyonu')
    plt.legend(loc=4)
    plt.axis([-2,2, 0,35])"""

#-----#

def createPatternArray(inputTiffFile, outputTiffFile):

```

```

#Tif dosyalarıyla devam..
tiffFileList = glob.glob(inputTiffFile + '/' + '*.tif')

myDict = {}
print ("\nGirdi dosyalar:\n")
for inputFileName in tiffFileList:
    baseName = os.path.basename(inputFileName)[-4]
    print (baseName)
    try:
        gdal.AllRegister()
        dosyam = gdal.Open(inputFileName)
        gt_wasRead = dosyam.GetGeoTransform()
        band = dosyam.GetRasterBand(1)
        rows = dosyam.RasterYSize
        cols = dosyam.RasterXSize
        bandValue = band.ReadAsArray()
        myDict[baseName] = bandValue
        dosyam = None
    except:
        print ("HATA: " + inputFileName + " dosyasi okunamadi...")
        continue #Dongunun basina doner (Sonraki Tiff dosyasini okur)

print ("\npatternArray olusturuluyor..")
patternArray = []
for yy in range(rows):
    for xx in range(cols):

        patternList = []
        for key,val in sorted(myDict.items(),key=operator.itemgetter(0)):

```

```

        #print (key, val[yy, xx])
        patternList.append(val[yy, xx])
    patternArray.append(patternList)
    #print('-'*55)
    patternArray = np.array(patternArray, dtype= np.float)
    print ("patternArray olusturuldu")
    print ("patternArray shape: ", patternArray.shape)

    return rows, cols, patternArray

def createTiffFile(row, col, ay, inputArray, outputPath):

    newArray = inputArray.reshape(row, col)
    #print ("-"*55, "\nReshapeArray:\n\n", newArray, newArray.shape)

    outName = outputPath + '/GS_2015' + ay + '.tif'

    driver = gdal.GetDriverByName("GTiff")
    ds = driver.Create(outName, col, row, 1, gdal.GDT_Float32)
    #ds.SetGeoTransform(gt_wasRead)
    ds.SetGeoTransform([25.0, 0.0057, 0, 43.0, 0, - 0.0057])
    outband = ds.GetRasterBand(1)
    outband.WriteArray(newArray)
    dsSRS = osr.SpatialReference()
    dsSRS.ImportFromEPSG(4326)
    ds.SetProjection(dsSRS.ExportToWkt())
    ds.FlushCache()
    ds = None

#-----#

```

```

def estimator(inputFile, inputTiffFile, outFiles, outTiffFile):

    rawData = np.loadtxt(inputFile, delimiter="\t", dtype=np.float64, skiprows=1)
    print ("rawData shape: ", rawData.shape)
    rawData[rawData < - 199.0] = np.nan#No image or can not open
    #rawData[(rawData[:,1] == 2015.0) & (rawData[:,2] == 7.0)] = np.nan
    rawData = rawData[~np.isnan(rawData).any(axis=1)]
    print ("rawData shape: ", rawData.shape)

    rawStation = list(set(rawData[:, 0]))
    badStation = [17070, 17074, 17201, 17722]
    print (badStation, len(badStation))

    for SC in rawStation:
        if SC in badStation:
            rawData[rawData[:, 0] == float(SC)] = np.nan

    rawData = rawData[~np.isnan(rawData).any(axis=1)]

    if not os.path.exists(outFiles): os.makedirs(outFiles)
    np.savetxt(outFiles + "/DATA_V3.txt", rawData, delimiter="\t", fmt="%2.4f")

    inputData = rawData[:, 1:33]
    targetData = rawData[:, -1]#.reshape(len(rawData), 1)

    scaler_input = StandardScaler().fit(inputData)
    norm_input = scaler_input.transform(inputData)

    print ("Input-Target shape: ", norm_input.shape, targetData.shape)

```



```

minX1, maxX1 = np.amin(norm_input), np.amax(norm_input)
print ("\nInput verisi min-max degerler: ", minX1, maxX1)
minX1, maxX1 = np.amin(targetData), np.amax(targetData)
print ("Target verisi min-max degerler: ", minX1, maxX1)

#lin_best_C = find_linear_parameters(norm_input, target_train)
best_inputs = find_best_inputs_set(norm_input, targetData, 1.5)
#penalty, gama = find_rbf_parameters(best_inputs, targetData)
best_svr = SVR(kernel='rbf',C=3.5,gamma=0.8,epsilon=0.1,\
               tol=0.001, cache_size=7000)

input_train, input_test, target_train, target_test =\
    train_test_split(best_inputs,targetData,\
                    test_size=0.3, random_state=0)

print ("\nTrain input-target shape: ", input_train.shape, target_train.shape)
print ("Test input-target shape: ", input_test.shape, target_test.shape)

my_learning_curve(best_svr, input_train, target_train, 3.5,0.8)

print ("\nVeri seti SVR ile egitiliyor...\n", "-"*50, sep="")
best_svr_fit = best_svr.fit(input_train, target_train)
print ("Tahmin yapiliyor...\n", "-"*50, sep="")
model_train = best_svr_fit.predict(input_train)
model_test = best_svr_fit.predict(input_test)

#sv_index = best_svr.support_
#print ("\nSupport_indices:\n\n",best_svr.support_, best_svr.support_.shape)

```

```

#print          ("\nSupport_vectors:\n\n",best_svr.support_vectors_,
best_svr.support_vectors_.shape)
#print("\ndual_coef:\n\n", best_svr.dual_coef_, best_svr.dual_coef_.shape)
print ("\nRO_rbf: ", best_svr.intercept_)
#print("\ndual_coef:\n\n",          best_svr.sample_weight,
best_svr.sample_weight.shape)
np.savetxt(outFiles + "/dualCoef.txt", best_svr.dual_coef_, delimiter="\t",
fmt="%2.4f")
np.savetxt(outFiles + "/suppVec.txt", best_svr.support_vectors_, delimiter="\t",
fmt="%2.4f")

#model_train, model_test = mlp_regressor(input_train, target_train, input_test)

print ('Negatif deger sayisi: ',model_train[model_train < 0].size,"---",\
      model_test[model_test < 0].size)

minX1, maxX1 = np.amin(model_train), np.amax(model_train)
print ("\nmodel_train min-max degerler: ", minX1, maxX1)
target_train = target_train[~(model_train < 0)]
model_train = model_train[~(model_train < 0)]
minX1, maxX1 = np.amin(model_train), np.amax(model_train)
print ("model_train min-max degerler: ", minX1, maxX1)

minX2, maxX2 = np.amin(model_test), np.amax(model_test)
print ("\nmodel_test min-max degerler: ", minX2, maxX2)
target_test = target_test[~(model_test < 0)]
model_test = model_test[~(model_test < 0)]
minX2, maxX2 = np.amin(model_test), np.amax(model_test)
print ("model_test min-max degerler: ", minX2, maxX2)

```

```

print ('Negatif deger sayisi: ',model_train[model_train < 0].size, "---",\
      model_test[model_test < 0].size)

print ("Egitim sonuclari degerlendiriliyor...\n", "-"*30, sep="")
model_evaluate(target_train, model_train)
print ("Test sonuclari degerlendiriliyor...\n", "-"*30, sep="")
model_evaluate(target_test, model_test)

np.savetxt(outFiles + "/true_train_V3.txt", target_train, delimiter="\t",
fmt="%2.4f")
np.savetxt(outFiles + "/true_test_V3.txt", model_test, delimiter="\t",
fmt="%2.4f")
np.savetxt(outFiles + "/model_train_V3.txt", model_train, delimiter="\t",
fmt="%2.4f")
np.savetxt(outFiles + "/model_test_V3.txt", model_test, delimiter="\t",
fmt="%2.4f")

line_plots(target_train, model_train, target_test, model_test)
scatter_plots(target_train, model_train, target_test, model_test)
##sv_plots(input_train, model_train, sv_index)

aylar = ['01','02','03','04','05','06','07','08','09','10','11','12']
for ay in aylar:
    inputFile = inputTiffFile + '/' + ay
    print ("-"*33, '\n', inputFile)
    satir, sutun, array = createPatternArray(inputFile, outTiffFile)
    scaler_input = StandardScaler().fit(array)
    norm_array = scaler_input.transform(array)
    print ('\nnorm_array shape: ', norm_array.shape)

```

```

minX1, maxX1 = np.amin(norm_array), np.amax(norm_array)
print ("norm_array min-max degerler: ", minX1, maxX1)

print ("\nTahmin yapılıyor..")
prediction = best_svr_fit.predict(norm_array)
createTiffFile(satir, sutun, ay, prediction, outTiffFile)
minX1, maxX1 = np.amin(prediction), np.amax(prediction)
print ("\nprediction min-max degerler: ", minX1, maxX1)

estimator("E:/===My_PhD_Thesis===/SVM/inputsMonthly/MonthlyInputTableV
2.txt",\
"E:/===My_PhD_Thesis===/SVM/inputsLayerMonthly",\
"E:/===My_PhD_Thesis===/SVM/outMonthly",\
"E:/===My_PhD_Thesis===/SVM/outMonthly/PredictedTiff")
#*****#

```