



**T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
BURDUR İLİNDE ARAZİLERİN GÜNEŞ ENERJİSİ
SANTRALLERİNE YÖNELİK UYGUNLUĞUNUN
DEĞERLENDİRİLMESİ**

Mustafa YÜCE

BURDUR, 2023

T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
BURDUR İLİNDE ARAZİLERİN GÜNEŞ ENERJİSİ
SANTRALLERİNE YÖNELİK UYGUNLUĞUNUN
DEĞERLENDİRİLMESİ

Mustafa YÜCE

Danışman: Prof. Dr. Ali Hakan IŞIK

II. Danışman: Doç. Dr. Murat İNCE

BURDUR, 2023

ETİK KURALLARA UYGUNLUK BEYANI

Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “**Makine Öğrenmesi Yöntemleriyle Burdur İlinde Arazilerin Güneş Enerjisi Santrallerine Yönelik Uygunluğunun Değerlendirilmesi**” başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

30/ 03/ 2023

(İmza)

Mustafa YÜCE

ÖNSÖZ

Bu araştırma için bana yol gösteren ve çalışmamı tamamlamada yardımlarını esirgemeyen Danışman Hocam Prof. Dr. Ali Hakan IŞIK'a ve Doç. Dr. Murat İNCE'ye teşekkürlerimi ve saygılarımı sunarım.

Ayrıca çalışmamı tamamlanmakta beni cesaretlendiren ve bana sabır gösteren eşim Didem YÜCE'ye ve biricik oğluma sevgilerimi sunarım.

Mart, 2023

Mustafa YÜCE



İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	iii
ÖZET	vii
ABSTRACT	viii
1. GİRİŞ	9
2. GENEL BİLGİLER	11
2.1. Enerji Kaynakları	11
2.2. Dünyada Enerji Mevcut Durumu	12
2.3. Türkiye’deki Güneş Enerji Santralleri	14
2.4. Burdur İli’ndeki Güneş Enerji Potansiyeli.....	17
2.5. Güneş’ten Elektrik Enerjisi Elde Eden Sistemler	18
2.5.1. Fotovoltaik Sistemler	19
2.5.2. Kristal Silikon Hücreler	20
2.5.3. İnce Film Hücreler	20
2.5.4. Yoğunlaştırılmış Güneş Enerjisi Sistemleri.....	20
2.6. Kaynak Özetleri	21
3. MATERYAL VE YÖNTEM	24
3.1. Güneş Enerji Santrallerinde Yer Seçimi	24
3.2. Çok Kriterli Karar Verme Yöntemleri	25
3.2.1. Analitik Hiyerarşi Süreci (AHP).....	26
3.3. Makine Öğrenmesi Algoritmaları	29
3.3.1. Rastgele Orman.....	30
3.3.2. Destek Vektör Makineleri	31
3.3.3. K-En Yakın Komşu Algoritması.....	32
3.3.4. XGBoost.....	32
3.3.5. AdaBoost.....	33
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	35
4.1. AHP Analizi	35
4.2. Makine Öğrenmesi Yöntemlerinin Karşılaştırılması	38
5. SONUÇ VE ÖNERİLER	43
KAYNAKLAR	45

ŞEKİLLER DİZİNİ

Şekil 2.1. Dünya birincil enerji tüketiminin kaynaklara göre dağılımı	12
Şekil 2.2. Dünyada kurulu PV kapasitesi.....	13
Şekil 2.3. Türkiye’de birincil enerji tüketiminin kaynaklara göre dağılımı	15
Şekil 2.4. Güneş Enerjisi Potansiyel Atlası (GEPA)	15
Şekil 2.5. Türkiye aylık ortalama radyasyon dağılımı.....	16
Şekil 2.8. Burdur ili aylık ortalama global radyasyon dağılımı.....	18
Şekil 2.9. Burdur ili aylık ortalama güneşlenme süreleri.....	18
Şekil 4.1. Burdur ili arazi uygunluk haritası	38
Şekil 4.2. Makine öğrenmesi algoritmaları veri seti bölgesi	39



ÇİZELGELER DİZİNİ

Çizelge 2.1. Enerji kaynakları	11
Çizelge 2.2. Dünyada birincil enerji tüketimleri.....	12
Çizelge 2.3. Dünyada yenilenebilir enerjinin üretim kaynaklarına göre dağılımı	13
Çizelge 2.4. 2021 yılı en yüksek PV kurulu kapasiteye sahip ülkeler.....	14
Çizelge 2.5. Türkiye’de 2021 yılı birincil enerji tüketimi	14
Çizelge 3.1. ÇKKV yöntemleri	26
Çizelge 3.2. Saaty önem derecesi ölçęęi	27
Çizelge 3.3. Rassal indeks	29
Çizelge 4.1. İkili karşılaştırma matrisi.....	36
Çizelge 4.2. Kriter ağırlıkları	36
Çizelge 4.3. GES uygunluk deęerleri ve renk skalası.....	37
Çizelge 4.4. Makine öğrenmesi algoritmaları için veri dağılımı	39
Çizelge 4.5. KNN algoritması karmaşıklık matrisi.....	40
Çizelge 4.6. RO algoritması karmaşıklık matrisi.....	40
Çizelge 4.7. DVM algoritması karmaşıklık matrisi	41
Çizelge 4.8. XGBOOST algoritması karmaşıklık matrisi	41
Çizelge 4.9. AdaBoost algoritması karmaşıklık matrisi	42
Çizelge 4.10. Makine öğrenmesi algoritmaları performansları	42

SİMGELER VE KISALTMALAR DİZİNİ

AHP	: Analitik Hiyerarşi Süreci
BMİDÇŞ	: Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi
CBS	: Coğrafi Bilgi Sistemleri
ÇKKV	: Çok Kriterli Karar Verme Yöntemleri
DVM	: Destek Vektör Makineleri
EJ	: Egzajul
ELECTRE	: Eliminasyon ET Regresyonu
FAHP	: Bulanık Analitik Hiyerarşi Süreci
GEPA	: Güneş Enerjisi Potansiyel Atlası
GES	: Güneş Enerjisi Santrali
GW	: Giga Watt
KNN	: K-En Yakın Komşu
KWh	: Kilo Watt Saat
MTA	: Maden Tetkik Arama Genel Müdürlüğü
MW	: Mega Watt
PV	: Fotovoltaik
PROMETHEE	: Preference Ranking Organization Method for Enrichment Evaluation
RO	: Rastgele Orman
TOPSIS	: İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği
TW	: Tera Watt
TWh	: Tera Watt-Saat
USGS	: Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
WOA	: Yerleşime Uygunluk Analizi

ÖZET

Yüksek Lisans Tezi

Burdur İlinde Güneş Enerjisi Santrallerine Yönelik Makine Öğrenmesi Yöntemleriyle Uygunluğunun Değerlendirilmesi

Mustafa Yüce

Burdur Mehmet Akif Ersoy Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ali Hakan Işık
II. Danışman: Doç. Dr. Murat İnce

Mart, 2023

Teknolojinin gelişmesi ve artan dünya nüfusu insanlığın enerjiye olan ihtiyacını giderek artırmaktadır. Enerji talebinin fosil kaynaklı yakıtlardan karşılanması çevre kirliliği ve karbon emisyonları dolayısıyla iklim değişikliğine neden olmaktadır. Ayrıca fosil kaynaklı yakıtların dünya üzerinde eşit dağılmamış olması nedeniyle bazı ülkelerin enerji arz güvenliği tehdit altındadır. Bu nedenlerden dolayı yenilenebilir enerjinin önemi hızla artmaktadır. Yenilenebilir enerjinin rüzgâr, güneş, biyokütle, hidrolik gibi kaynakları bulunmaktadır. Bu tez çalışmasında yenilenebilir enerji kaynaklarından güneş enerjisinin dönüşümü ile enerji elde edilen fotovoltaik güneş enerjisi santrallerinin düşük maliyetli ve verimli kullanılabilmesi açısından önemli katkısı olan yer seçimi faktörü ele alınmıştır. Burdur ilinde fotovoltaik güneş enerjisi santrallerinin kurulabileceği alanların uygunluğunun çok kriterli karar verme yöntemlerinden biri olan Analitik Hiyerarşi Prosesi (AHP) kullanılarak elde edilen veri ile makine öğrenmesi algoritmaları eğitilmiş ve algoritmaların performansları karşılaştırılmıştır. K-En yakın komşu, rastgele orman, destek vektör makineleri, XGBoost algoritmaları kullanılarak yapılan değerlendirmelerde %99'un üzerinde doğruluk oranlarıyla sınıflandırma yapılmıştır.

Anahtar Kelimeler: makine öğrenmesi, çok kriterli karar verme, güneş enerji santralleri, analitik hiyerarşi süreci, XGBoost

ABSTRACT

M. Sc. Thesis

Evaluation of Suitability of Lands for Solar Power Plants in Burdur Province with Multi-Criteria Decision Making Methods

Mustafa Yüce

**Burdur Mehmet Akif Ersoy University
Graduate School of Natural and Applied Sciences
Computer Engineering Department**

**Supervisor: Prof. Ali Hakan Işık
Co-Supervisor: Assoc. Prof. Murat İnce**

March, 2023

The development of technology and the increasing world population are leading to a growing demand for energy. For satisfying this demand causes environmental pollution and climate change due to carbon emissions. Moreover, the uneven distribution of fossil fuel resources around the world threatens the energy security of some countries. According to this reasons, the importance of renewable energy is rapidly increasing. Renewable energy sources include wind, solar, biomass, and hydro power. In this thesis, the site selection factor, which is crucial for low-cost and efficient use of photovoltaic solar power plants that convert solar energy into electricity, is evaluated. The suitability of areas in Burdur province in terms of photovoltaic solar power plants installation was evaluated using the Analytic Hierarchy Process (AHP), which is one of the multi-criteria decision-making methods. Machine learning algorithms were trained with the data obtained by AHP, and the performances of the algorithms were compared. Classification was performed with accuracy rates of over 99% using K-Nearest Neighbor, Random Forest, Support Vector Machines and XGBoost algorithms.

Keywords: machine learning, multi-criteria decision making, solar power plants, analytical hierarchy process, XGBoost

1. GİRİŞ

Bir toplumun ekonomik ve sosyal gelişiminin en önemli ihtiyaçlarından biri enerjidir. Özellikle sanayi devriminden bu yana sürekli ve hızla gelişen teknoloji ve nüfus artışı beraberinde de artan bir enerji ihtiyacını ortaya çıkarmaktadır.

Enerji talebini karşılamak amacıyla geleneksel enerji kaynakları olan kömür, petrol, doğalgaz gibi fosil yakıtların kullanımı en başta küresel ısınma gibi çevre açısından problemlere neden olmaktadır. Fosil kaynakların sınırlı olması ve arzının belli ülkelerden sağlanması enerji ihtiyacının sürdürülebilir bir şekilde karşılanması açısından bir tehdit oluşturmaktadır. Tüm bu nedenlerden dolayı temiz, ekonomik ve sürdürülebilir enerji kaynaklarına erişim toplumların refahı ve sürdürülebilir gelişimi için son derece önemlidir.

İklim değişikliğine sebep olan karbondioksit ve diğer sera gazlarının emisyonlarının azaltılması, ormanlar, okyanuslar gibi sera gazı yutaklarının korunması ve araştırma ve teknoloji üzerinde iş birliği yapılması amacıyla 1992 yılında Rio de Janeiro’da düzenlenen Birleşmiş Milletler (BM) Çevre ve Kalkınma Konferansı’nda Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (BMİDÇS) imzaya açılmış ve 1994’te yürürlüğe girmiştir.

1997 yılında BMİDÇS’nin ilk uygulama anlaşması niteliğinde olan Kyoto Protokolü, kabul edilmiş ve protokol 2005’te yürürlüğe girmiştir. Kyoto Protokolü’nün iki taahhüt dönemi bulunmaktadır. Kyoto Protokolü’nün 2013-2020’yi kapsayan 2. taahhüt Döneminde taraf ülkeler 1990 yılına göre sera gazı emisyonlarını %18 azaltmayı kararlaştırmıştır. Kyoto Protokolünün 2. taahhüt dönemi 31 Aralık 2020 tarihinde yürürlüğe girmiştir. Kyoto protokolünün ardından 2020 sonrası iklim rejimini düzenleyen Paris Anlaşmasının yürürlüğe girmiştir.

2020 sonrası iklim değişikliği rejiminin çerçevesini oluşturan Paris Anlaşması, 2015 yılında Paris’te düzenlenen BMİDÇS 21. Taraflar Konferansı’nda kabul edilmiş ve ilk kez küresel ölçekte bütün ülkeler sera gazı emisyon azaltımı taahhüdünde bulunmuşlardır. Anlaşma, 5 Ekim 2016 itibariyle, küresel sera gazı emisyonlarının %55’ini oluşturan en az 55 tarafın anlaşmayı onaylaması koşulunun karşılanmasıyla, 4 Kasım 2016 itibariyle yürürlüğe girmiştir (T.C Dışişleri Bakanlığı, 2023).

İklim değişikliğinin ve sürdürülebilir ekonominin oluşturulması için devletlerin Kyoto Protokolü ve Paris Anlaşması çerçevesinde vermiş oldukları taahhütlerin yerine

getirilebilmesi açısından yenilenebilir enerji dönüşümünün sağlanması çok önemli bir adımdır.

Bu çalışmada en yaygın olarak kullanılan yenilenebilir enerji çeşitlerinden güneş enerjisinin verimli ve ekonomik olarak kullanılabilir enerjiye dönüştürülebilmesi amacıyla önemli faktörlerden biri olan GES'lerde yer seçimi ele alınmıştır. GES'ler için yer seçiminde etkili olabilecek kriterler seçilmiş ve bu kriterlere dayanarak Burdur ili genelinde bir uygunluk haritası oluşturulmuştur. GES yer seçiminde makine öğrenmesi yöntemlerinin etkinliğini ve bu yöntemlerin uygulanabilirliğini değerlendirmek üzere Rasgele Orman, Destek Vektör Makineleri, K-En Yakın Komşu, XGBoost ve AdaBoost algoritmalarıyla GES için yer seçiminde elde edilen sonuçlar incelenmiştir.



2. GENEL BİLGİLER

2.1. Enerji Kaynakları

Enerji kaynakları kullanılışlarına göre yenilenebilir ve yenilenemez enerji kaynakları olmak üzere 2 gruba ayrılmaktadır. Doğal bir çevrim sürecinde aynen kalabilen, kullanılmasına rağmen tükenmeyen enerji kaynaklarına yenilenebilir enerji kaynakları; doğada sınırlı olarak bulunan ve kullanıldığında yenilenemeyen kaynaklara ise yenilenemez enerji kaynakları adı verilir (Koç ve Kaya, 2015).

Enerji kaynaklarının diğer bir sınıflandırma şekli ise dönüştürülebilirliklerine göre yapılan sınıflandırmadır. Bu sınıflandırmaya göre enerji kaynakları primer ve sekonder enerji kaynakları olarak ikiye ayrılmaktadır. Enerjinin herhangi bir değişim ya da dönüşüme uğramamış şekli birincil(primer), birincil enerjinin dönüştürülmesiyle elde edilen enerji ise ikincil (sekonder) enerji kaynakları olarak ifade edilmektedir (Koç ve Kaya, 2015). Çizelge 2.1’de enerji kaynaklarının sınıflandırılması gösterilmektedir.

Çizelge 2.1. Enerji kaynakları (Koç ve Kaya, 2015)

ENERJİ KAYNAKLARI	
Kullanılışlarına Göre Enerji Kaynakları	Dönüştürülebilirliklerine Göre Enerji Kaynakları
1- Yenilenemez Enerji Kaynakları A-Fosil Kaynaklı +Kömür +Petrol +Doğalgaz B- Çekirdek Kaynaklı +Uranyum +Toryum	1-Birincil(Primer) Enerji Kaynakları A-Fosil Kaynaklı +Kömür +Güneş +Rüzgâr +Dalga +Petrol +Biyokütle +Hidrolik +Doğalgaz +Nükleer
2- Yenilenebilir Enerji Kaynakları +Hidrolik +Güneş +Jeotermal +Dalga +Hidrojen +Biyokütle +Rüzgâr	2- İkincil Enerji Kaynakları +Hava gazı +Elektrik, Motorin, Benzin +İkincil Kömür +Kok, Petro kok +LPG


2.2. Dünyada Enerji Mevcut Durumu

Dünyada birincil enerji tüketiminde 2020 yılında sert bir düşüş yaşanmış toplam tüketim 564 EJ değerine gerilemiştir. Ancak 2021 yılında ise sert bir yükselişle 595 EJ seviyesine gelmiştir. Dünya birincil enerji tüketim değerleri Çizelge 2.2’de verilmiştir.

Çizelge 2.2. Dünyada birincil enerji tüketimleri (BP, 2022)

Yıl	Dünya Birincil Enerji Tüketimi (EJ)
2017	566
2018	582
2019	587
2020	564
2021	595

2021 yılı için dünyada toplam birincil enerji tüketiminin yaklaşık %82’si petrol, kömür ve doğalgazdan karşılanmaktadır. Yenilenebilir enerjinin payı ise %6,61’dir (BP, 2022). Birincil enerji tüketiminin kaynaklara göre dağılımı Şekil 2.1’de verilmiştir.




Şekil 2.1. Dünya birincil enerji tüketiminin kaynaklara göre dağılımı (BP, 2022)

2020 ve 2021 yıllarında sırasıyla 3146,6 ve 3657,2 TWh yenilenebilir kaynaklı enerji üretilmiştir. Yenilenebilir enerjinin üretim kaynaklarına dağılımı Çizelge 2.3’de verilmiştir.

Çizelge 2.3. Dünyada yenilenebilir enerjinin üretim kaynaklarına göre dağılımı (BP, 2022)

	2020		2021	
	Üretim (TWh)	Oran %	Üretim (TWh)	Oran %
Rüzgâr	1596,4	50,74%	1861,9	50,91%
Güneş	846,2	26,89%	1032,5	28,23%
Diğer	703,9	22,37%	762,8	20,86%
Toplam	3146,5	100,00%	3657,2	100,00%

2021 yılı rakamlarına göre dünyada kurulu PV güneş enerjisi kapasitesi 843,1 GW'tır. Son 5 yılda dünyada PV güneş enerjisi kapasitesinin değişimi Şekil 2.2'de verilmiştir.



Şekil 2.2. Dünyada kurulu PV kapasitesi (BP, 2022)

2021 yılı verilerine göre dünyada PV güneş enerjisi kurulu kapasitesi en yüksek ülke 306,4 GW'la Çin'dir. Çin'i sırasıyla ABD, Japonya, Almanya ve Hindistan takip etmektedir. 2021 yılı en yüksek PV kurulu kapasiteye sahip 5 ülke Çizelge 2.4'de verilmiştir.

Çizelge 2.4. 2021 yılı en yüksek PV kurulu kapasiteye sahip ülkeler (BP, 2022)

	Kurulu Kapasite (GW)
Çin	306,4
ABD	93,7
Japonya	74,2
Almanya	58,5
Hindistan	49,3


2.3. Türkiye'deki Güneş Enerji Santralleri

Türkiye'nin 2020 yılı birincil enerji tüketimi 6,44 EJ'dir. Bu rakam 2021 yılında ise 6,83 EJ değerine ulaşmıştır. Türkiye'nin son 5 yılda birincil enerji tüketimi değişimleri Çizelge 2.5'de verilmiştir.

Çizelge 2.5. Türkiye'de 2021 yılı birincil enerji tüketimi (BP, 2022)

	Türkiye Birincil Enerji Tüketimi (EJ)
2017	6,43
2018	6,36
2019	6,60
2020	6,44
2021	6,83

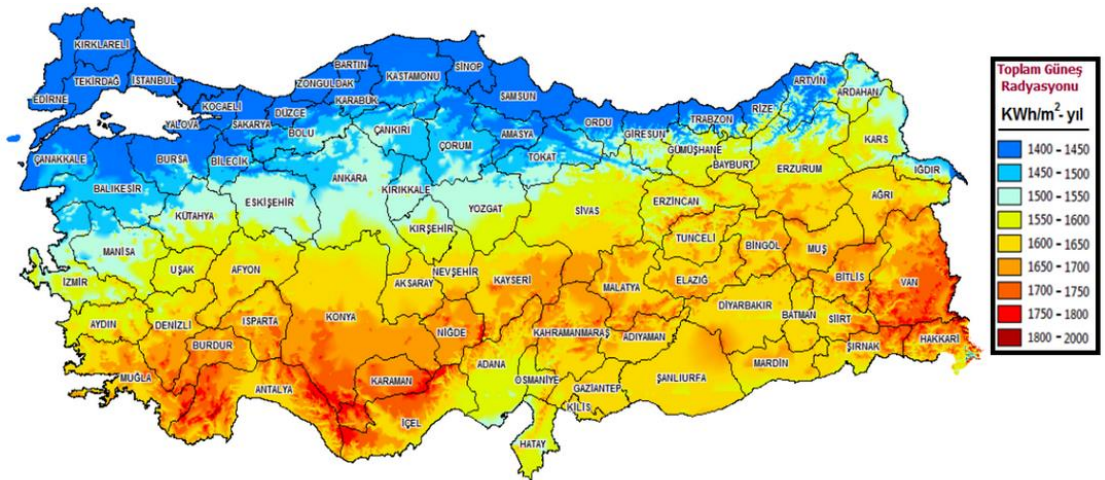
2021 yılında Türkiye'de toplam birincil enerji tüketiminin yaklaşık %83,43'sü petrol, kömür ve doğalgazdan karşılanmaktadır. Yenilenebilir enerjinin payı ise %8,94'tür. (BP, 2022). Birincil enerji tüketiminin kaynaklara göre dağılımı Şekil 2.3'te verilmiştir.



Şekil 2.3. Türkiye’de birincil enerji tüketiminin kaynaklara göre dağılımı (BP, 2022)


Türkiye’nin 2023 yılı Ocak ayı sonu itibarıyla elektrik enerjisi üretimi kurulu gücü 104.038 MW’a ulaşmıştır. Kurulu gücün kaynaklara göre dağılımı ise %30,3’ü hidrolik enerji, %24,4’ü doğal gaz, %21’i kömür, %11’i rüzgâr, %9,2’si güneş, %1,6’sı jeotermal ve %2,5 diğer kaynaklar şeklindedir (Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Türkiye, coğrafi konumu nedeniyle önemli bir güneş enerjisi potansiyeline sahiptir. Enerji ve Tabii Kaynaklar Bakanlığınca, Türkiye’nin güneş enerjisi potansiyelini ortaya koyan Türkiye Güneş Enerjisi Potansiyeli Atlası (Şekil 2.4) hazırlanmıştır.




Şekil 2.4. Güneş Enerjisi Potansiyel Atlası (GEPA)

GEPA'ya göre, Türkiye için ortalama yıllık toplam güneşlenme süresi 2.741 saat olup ortalama yıllık toplam ışınım değeri 1.527,46 KWh/m² olarak hesaplanmıştır. GEPA'ya göre aylık ortalama global radyasyon dağılımı Şekil 2.5'da yer almaktadır.




Şekil 2.5. Türkiye aylık ortalama radyasyon dağılımı (GEPA)

Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre Haziran 2022 sonu itibariyle Türkiye'de güneş enerjisine dayalı elektrik kurulu gücü 8.479 MW, toplam kurulu güç içerisindeki oranı ise %8,35'tir. Güneş enerjisine dayalı yıllara göre kurulu güç değişimi ve toplam kurulu güç içerisindeki oranı Şekil 2.6 ve Şekil 2.7'de verilmektedir.



Şekil 2.6. Türkiye’de güneş enerjisi kurulu güç değişimi (Enerji ve Tabii Kaynaklar Bakanlığı, 2023)




Şekil 2.7. Türkiye’de güneş enerji kurulu gücünün toplam kurulu güç içindeki oranı (Enerji ve Tabii Kaynaklar Bakanlığı, 2023)


2.4. Burdur İli’ndeki Güneş Enerji Potansiyeli

GEPA’ya göre Burdur ili ortalama yıllık toplam güneşlenme süresi 2948 saat olup ortalama yıllık toplam ışıınım değeri 1635,64,46 KWh/m²’dir. GEPA’ya göre aylık

ortalama global radyasyon dağılımı ve güneşlenme süreleri sırasıyla Şekil 2.8 ve Şekil 2.9'da yer almaktadır.



Şekil 2.8. Burdur ili aylık ortalama global radyasyon dağılımı (GEPA)



Şekil 2.9. Burdur ili aylık ortalama güneşlenme süreleri (GEPA)

2.5. Güneş'ten Elektrik Enerjisi Elde Eden Sistemler

Güneş enerjisi, güneşte meydana gelen nükleer füzyon tepkimeleri sonucunda açığa çıkar ve dünyaya ışıma yoluyla ulaşır. Güneşten gelen ışınların yeryüzünde ısı ve elektrik enerjisine dönüştürülmesiyle elde edilen bir yenilenebilir ve doğal bir enerji türüdür.

Güneş enerjisi temel olarak iki farklı prensiple üretilir. Bunlardan birincisi fotovoltaik sistemleridir. Yarı iletken malzemenin güneş pili olarak çalışması, güneş hücresinin ara yüzeyine gelen fotonların buradan elektron sökmesi ve sökülen elektronların dış çevrede hareket ederek elektrik akımı oluşturması prensibine dayanır (Turhan ve Çetiner, 2012).

Diğer bir yöntem ise yoğunlaştırılmış güneş enerjisi sistemleridir. Bu yöntemde güneş ışığı heliostatlar, parabolik aynalar veya çanaklar gibi parlak yüzeylerden yansıtılarak belirli noktalarda odaklanır ve odak noktasında ısı birikimi sağlanır. Elde edilen ısı ile buharlı güç çevrimleri yardımıyla elektrik enerjisi elde edilir.

2.5.1. Fotovoltaik Sistemler

Fotovoltaik sistemler güneş enerjisini doğrudan elektrik enerjisine dönüştürürler. En küçük birimi yarı iletken malzemelerden üretilen güneş hücreleridir. Elde edilen gücü artırmak için hücreler bir araya getirilerek güneş modülleri, güneş modülleri bir araya getirilerek ise güneş panelleri oluşturulur. GES'ler ise güneş panellerinin bir araya getirilerek oluşturulur.

Fotovoltaik panellerin elektrik üretimi güneş ışığının geliş açısıyla doğrudan ilgilidir dolayısıyla elektrik üretim miktarı, konuma, hava durumuna, mevsimlere ve günün saatlerine doğrudan bağlıdır. Ancak çok az ışık koşullarında bile üretim yapılabilir. PV güneş enerjisi üretimi diğer yenilenebilir enerji türlerine göre daha düşük maliyetlidir, PV panellerin ömürleri uzundur ve bakım maliyetleri nispeten düşüktür. Elektrik üretiminin değişken olması ve en yüksek üretim koşullarında depolama maliyetlerinin yüksek olması fotovoltaiklerin dezavantajlarındanır.

Güneş hücreleri için en yaygın kullanılan malzemelerden biri silisyumdur. Silisyumun yanı sıra amorf silisyum, , kadmiyum tellür (CdTe), bakır indiyum selenoid (CIS), bakır indiyum galyum selenoid (CIGS) hücre yapımında yaygın olarak tercih edilen malzemelerdir (Turhan ve Çetiner, 2012).

Fotovoltaik hücreler kristal silikon hücreler, ince film hücreler olmak üzere sınıflandırılmaktadır. Ayrıca henüz kullanımı yaygın olmayan 3. nesil olarak sınıflandırılan güneş hücreleri bulunmaktadır. Süpertandem, kuantum parçacık, sıcak taşıyıcı, organik güneş hücreleri gibi güneş hücreleri 3. nesil güneş hücreleri olarak bilinirler.

2.5.2. Kristal Silikon Hücreler

Kristal silikon hücreler silisyum dioksit bileşiminin (SiO_2) yüksek ısılarda ısı işlem uygulanarak saflaştırılmasıyla elde edilir. Kristal silikon hücreler ise kendi içinde monokristal ve polikristal hücreler olmak üzere ikiye ayrılır. (Oğuz, Karakan, & Uslu, 2015)

Monokristal hücreler pahalı olmasına rağmen verimlilik değerleri en yüksek güneş hücreleridir. Verimlilikleri kullanım yerine, konuma vb. faktörlere göre değişmekle beraber % 15-18 arasında değişmektedir. Polikristal hücreler tek bir kristalden oluşmamış heterojen yapıdadır. Bu nedenle üretimleri daha kolay ve ucuz ancak verimleri monokristal hücrelere göre daha düşüktür.

2.5.3. İnce Film Hücreler


İnce film güneş pilleri, ince bir tabaka şeklinde yarı iletken malzemelerin kullanıldığı güneş pilleridir. Bu güneş pilleri, geleneksel silikon tabanlı güneş pillerine göre daha az yarı iletken malzeme kullanarak daha ince dolayısıyla daha hafiftirler. İnce yapıda üretilebildiklerinden daha esneklerdir. Teknolojisine göre değişmekle beraber verimlilikleri %5-20 arasında değişmektedir.

Yaygın olarak kullanılan üç türü bulunmaktadır.

1. Amorf silikon(a-Si)
2. Kadmiyum tellür(cdTe)
3. Bakır indiyum galyum diselenid (CIGS)

2.5.4. Yoğunlaştırılmış Güneş Enerjisi Sistemleri

Yoğunlaştırılmış güneş enerjisi sistemleri, güneş ışığını yansıtıcılar vasıtasıyla belli bir bölgede yoğunlaştırarak ısı enerjisine çevrilmesini ve elde edilen ısının buharlı güç çevrimlerinde kullanılarak elektrik enerjisi üretimini sağlamaktadır. Bu tip sistemlerde güneş enerjisi toplama sistemlerinin yanında ısı enerjisinin depolandığı tank ve buharlı güç çevrimi ekipmanlarının bulunması gereklidir. Dolayısıyla maliyetleri PV sistemlere göre verimleri fazla olmasına karşın maliyetleri daha fazladır. Şekil 2.10'da yoğunlaştırılmış güneş enerji sisteminin yapısı gösterilmektedir.



Şekil 2.10. Yoğunlaştırılmış güneş enerjisi sistemi (Bayraktar, 2020)

2.6. Kaynak Özetleri

Merrouni vd. Doğu Fas'ın büyük ölçekli PV tarlalarının potansiyelini CBS ve AHP yöntemlerini kullanarak değerlendirmişlerdir (Merrouni vd., 2018). Özdemir ve Şahin AHP yöntemini kullanarak seçilen nitel ve nicel faktörler ışığında üç farklı lokasyonunu GES kurulumu için uygunluğunu değerlendirmiştir (Ozdemir ve Sahin, 2018).

Güngör ve Akar tarafından farklı konumsal çözünürlüğe ve karakteristiğe sahip çok bantlı uygu görüntüleri kullanılarak Rastgele Orman algoritmasının performansı incelenmiştir. Bu doğrultuda elde edilen sınıflandırma sonuçları Gentle AdaBoost (GAB), en Çok Benzerlik (EÇB) ve Destek Vektör Makineleri (DVM) algoritmalarından elde edilen sonuçlarla karşılaştırılmıştır. Çalışmadan elde edilen sonuçlara göre RO algoritması DVM'den %10 daha yüksek sınıflandırma doğruluğu vermiştir. GAB algoritması ise RO'dan %14 daha düşük sınıflandırma doğruluğu göstererek ele alınan algoritmalar arasında en düşük doğruluğu göstermiştir (Güngör ve Akar, 2012).

Jung vd. çatı üstü PV sistemlerinin optimal planlanması amacıyla coğrafi bilgi sistemleri tabanlı pekiştirilmiş öğrenme modeli geliştirmişlerdir. Çatı üstü PV sistem kurulabilmesi için konumsal verilerin elde edilmesi amacıyla CBS kullanılmış, çeşitli lokasyonlarda ve gelecek senaryolarında çatı üstü PV kurulumundan azami ekonomik fayda elde edilmesi amacıyla pekiştirilmiş öğrenme modeli geliştirilmiştir. Geliştirilen model Genetik Algoritma, Parçacık Sürü Optimizasyonu gibi diğer planlama modellerine göre %4.4 daha iyi performans göstermiştir (Jung vd., 2021).

Musbah vd. tarafından yapılan çalışmada uzak bir bölgeyi elektrikleştirme amacıyla bir hibrit enerji sistemi olarak rüzgâr, benzin ve dizel jeneratörü kullanılmıştır. Hibrit enerji sisteminin kaynakları, beş kriter kullanılarak tüm mevcut altı enerji kaynağı kombinasyonundan en iyi kombinasyonu seçmek için farklı düzeneklerde sınıflandırılmıştır. Çalışmanın ilk aşamasında, veri kümesi beş kriterin hesaplanması için modelleme ve hesaplama için kullanılmaktadır. TOPSIS yönteminin sonuçları, beş kriter ve talep tarafıyla bir veri kümesi oluşturmak için birleştirilmektedir. İkinci aşamada ise makine öğrenimi algoritmalarından rastgele orman ve LightGBM algoritmaları enerji kaynaklarının kombinasyonunun tahminini doğrulamak amacıyla kullanılmaktadır. Algoritmaların değerlendirilmesi, RF algoritmasının LightGBM algoritmasına göre %81,81 doğruluk oranıyla üstünlüğünü göstermektedir (Musbah vd., 2022).

Choudhary vd., Hindistan'ın üst Godavari alt havzasında uygun yeraltı suyu potansiyel bölgelerini belirlemek için farklı bivariate, çok kriterli karar verme, topluluk (ensembled) ve makine öğrenmesi modelleri kullanarak yeraltı suyu potansiyel alanlarını haritalandırmayı amaçlamıştır. Seçilen modeller arasında Weight of Evidence (WoE), TOPSIS, Fuzzified Functional Ratio (F-FR), XGBoost ve Extremely Randomized Trees modelleri yer almaktadır. Toplam 15 yeraltı suyu faktörü dikkate alınmış ve sonuçta en iyi model WoE-TOPSIS-F_FR olarak seçilmiştir. Çalışma sonuçları, gelişmiş ML modellerine kıyasla ensembled bivariate ve MCDM modelinin daha yüksek doğruluğa sahip olduğunu göstermektedir. Tahmin edilen istatistiksel özelliklerde de yüksek bir korelasyon gözlemlenmiştir. Bu nedenle, topluluk modelinin, yer altı suyu potansiyel alanlarını haritalandırmak için gelişmiş ML modelleri yerine kullanılabileceği ifade edilmiştir (Choudhary vd., 2022).

Dahooie vd. tarafından yapılan çalışmada İran'da güneş enerjisi santralleri için en uygun konumu belirlemek amacıyla ÇKKV yöntemleri kullanılmaktadır. Çalışmada öncelikle Karar verme alternatiflerinin bir listesi hazırlanmış ve bu alternatifler kriterler açısından coğrafi bilgi sistemleri (GIS) yazılımı kullanılarak değerlendirilmiştir. Daha sonra karar vericiler, SWARA ve TOPSIS, TODIM, WASPAS, COPRAS, ARAS ve MULTIMOORA gibi farklı sıralama yöntemlerini içeren MCDM yöntemlerini kullanarak belirlenen alternatifleri önceliklendirmiştir. Son olarak, CCSD yöntemi ile sonuçlar birleştirilmiş ve GES'ler için en iyi konum belirlenmiştir. Çalışma ile önerilen yaklaşımın önceki yöntemlerin sonuçları ile yüksek bir korelasyona sahip olduğu ve önceki yöntemlerin sınırlamalarını aşabilme yeteneğini gösterdiği öne sürülmüştür (Dahooie vd., 2022).

Shahab ve Singh kullanarak bir konum için en uygun yenilenebilir enerji kaynağı türünün belirlenmesi amacıyla farklı makine öğrenmesi algoritmalarının performansını karşılaştırmıştır. İlgili çalışmada Amerika Birleşik Devletleri (ABD) sınırları içindeki alanda rüzgâr, yağış, eğim, güneş radyasyonu gibi coğrafi özelliklerden oluşan veri setini kullanarak KNN, RO, DVM, Karar Ağacı ve Yapay Sinir Ağları algoritmalarının performansını incelemiştir. Sınıflandırmaya göre en iyi sonucu RO algoritması vermiştir. Daha sonra RO algoritmasını kullanarak göre ABD'nin arazisini rüzgâr, güneş ve jeotermal enerji üretimi açısından sınıflandırmışlardır (Shabab ve Singh, 2019).

Literatürdeki araştırmalar incelendiğinde güneş enerjisi santrallerinin kurulumu için alan araştırmasına yönelik çok kriterli karar verme yöntemlerinin kullanıldığı fazla sayıda çalışma vardır. Ancak makine öğrenmesi yöntemlerinin kullanılarak GES için uygun alan seçimine yönelik oldukça sınırlı sayıda çalışma bulunmaktadır. Bu çalışma kapsamında, Burdur ilinin coğrafi yapısı seçilen kriterler doğrultusunda analiz edilecek ve elde edilen sonuçlar ile makine öğrenmesi algoritmaları eğitilerek GES yer seçimi kapsamında algoritmaların performansları değerlendirilecektir.

3. MATERYAL VE YÖNTEM

Burdur ilinde yer alan arazilerin GES açısından uygunluğunu değerlendirmek için 30 metre x 30 metre boyutundaki arazi parçaları belirlenen 7 kriter açısından puanlanarak ÇKKV yöntemlerinden biri olan AHP yöntemiyle uygunluk değerleri CBS ortamında QGIS programıyla hesaplanmıştır. AHP yöntemi ile 0-10 aralığında puanlanan arazi parçaları:

- Uygun Değil
- Düşük Uygunluk
- Uygun
- Yüksek Uygunluk

olmak üzere 4 sınıfta sınıflandırılmıştır. Sınıflandırma sonucuna göre CBS ortamında arazi uygunluk haritası oluşturulmuştur. Oluşturulan uygunluk haritasının 1200x1200 piksellik kısmına ait veriler makine öğrenmesi yöntemlerinin sonuçlarının karşılaştırılması amacıyla eğitim test verisi olarak kullanılmıştır. Makine öğrenmesi algoritmalarından KNN, DVM, RO, XGBoost ve AdaBoost kullanılmıştır.

3.1. Güneş Enerji Santrallerinde Yer Seçimi

GES'lerin kurulumunda verimli çalışma, kurulum ve işletme maliyetleri açısından uygun yer seçimi son derece önemlidir. Yer seçimine etki eden oldukça fazla faktör vardır.

Yıllık güneşlenme süreleri ve güneşlenme miktarları arazinin bulunduğu konumla doğrudan ilgili olan faktörlerdendir. Ayrıca arazinin bakışı ve gölgelenme durumu güneş ışınlarından verimli olarak faydalanılabilmesi açısından önem arz eder. Bakı açısından, arazinin Güney, güneydoğu cepheli olması PV panelleri daha fazla güneş ışığı alabilmesini dolayısıyla daha verimli çalışabilmesini sağlayacaktır.

Arazinin yasal olarak GES kurulumuna izin verilebilecek konumda olması gerekir. Tarım ve orman arazileri üzerinde veya SİT alanları üzerinde GES kurulumuna izin verilmemektedir.

Yatırım ve işletme maliyetleri açısından arazinin yola yakınlığı, enerji nakil hatlarına yakınlığı da GES'in kurulumunda karar vericinin göz önünde bulundurması gereken kriterlerdendir.

Arazinin eğimi ilk kurulumda arazinin GES için uygun hale getirilebilmesi açısından önemlidir. Genellikle eğimin %10'dan aşağıda olması istenir. Yüksek eğimli arazilerde GES kurulumu için hafriyat giderleri fazla olacaktır.

Arazinin fay hatlarında uzaklığı yatırımın deprem riskinden uzak tutulması açısından önemlidir.

GES kurulacak alanların, mermer ocağı, taş ocağı gibi toz kaynaklı kirleticilerden uzakta bulunması gereklidir. Çünkü mermer tozu, kaya tozu gibi partiküller PV panellerinin üzerinde birikerek panellerin verimliliğini düşürecek ve panellerin daha sık temizlik gerektirmesi sebebiyle işletme maliyetlerini artıracaktır.

Tüm örnek gösterilen kriterlerin yanında karar verici açısından bir çok kriter bulunmaktadır. Karar verici fırsat ve maliyetleri göz önünde tutarak belirlediği kriterler açısından en ekonomik ve sürdürülebilir kararı vermelidir.

Kriterlerin çokluğu, radyasyon ve güneşlenme süreleri gibi objektif kriterlerin yanı sıra arazinin mülkiyeti, yerleşim yerlerine yakınlığı, iklim koşulları istihdam olanakları gibi objektif veya sübjektif kriterlerin karar verme sürecine dâhil edilmesi süreci zorlaştırmaktadır.

Bu sebeple ÇKKV yöntemlerinden AHP yöntemiyle karar verici açısından yer seçimini etkileyen kriterler birbirleri açısından bağıl önem dereceleri hesaba katılarak objektif kararlar alınabilir ve karar verme süreci daha basit hale getirilebilir.

3.2. Çok Kriterli Karar Verme Yöntemleri

Çok kriterli karar verme (ÇKKV) birden fazla kriterin bir arada değerlendirilerek alternatiflere değerler atama süreci olarak ifade edilmektedir. Başka bir ifade ile belirlenen bir amaç doğrultusunda, karar verici açısından amacın elde edilmesinde etkili olan kriterlerin bir arada değerlendirilerek, amacı gerçekleştirmeye yönelik en uygun tercihin yapılmasıdır.

ÇKKV yaklaşımları çok nitelikli karar verme ve çok amaçlı karar verme olmak üzere iki ana sınıfta incelenebilir. Eğer problem sonlu sayıda alternatifler kümesinden belirli niteliklerin puanlanmasına göre en iyi alternatifin seçimini kapsıyor ise bu karar verme yöntemine çok nitelikli karar verme (ÇNKV) adı verilir. Eğer karar verme bir dizi çelişen amaca dayalı olarak en iyi alternatifin seçimine dayanıyorsa bu yöntem çok amaçlı karar verme (ÇAKV) adı verilir. Her iki problem tipinde de bir ya da birden fazla karar verici vardır (Karaatlı vd., 2015).

ÇKKV problemleri seçim, sınıflama ve sıralama problemleri olmak üzere 3 temel gruba ayrılır. Seçim problemleri için kullanılan tekniklerin sonucunda, birçok alternatif arasından en faydalı olanın hangisi olduğuna karar verilir. Sınıflama teknikleri, alternatifleri gruplandırırken kullanılır sıralama teknikleri ise alternatifler arasında sıralama yapmaktadır. Yaygın olarak kullanılan ÇKKV yöntemleri Çizelge 3.1’de verilmiştir (Dalbudak ve Rençber, 2022).

Çizelge 3.1.ÇKKV yöntemleri (Dalbudak ve Rençber, 2022)

Seçim Problemleri	Sınıflandırma Problemleri	Sıralama Problemleri
-AHP -ANP -MAUT/UTA -MACBETH -PRTOMETHEE -ELECTRE I -TOPSIS -Hedef Programlama	-AHP -ANP -MAUT/UTA -MACBETH -PRTOMETHEE -ELECTRE III -TOPSIS	-AHPSoft -UTADIS -FlowSort -ELECTRE III

3.2.1. Analitik Hiyerarşi Süreci (AHP)

Analitik Hiyerarşi Süreci (AHP) çok kriterli bir karar verme yöntemidir. İlk olarak 1968 yılında Myers ve Alpet tarafından ortaya koyulmuş ve 1977 yılında Thomas Saaty tarafından karar verme problemlerinin çözümünde kullanılabilir bir yöntem olarak geliştirilmiştir. AHP bir karar hiyerarşisi üzerinde önceden tanımlanmış bir karşılaştırma skalası kullanılarak gerek kararı etkileyen faktörler gerekse de bu faktörler açısından karar noktalarının önem değerleri açısından, birebir karşılaştırmalara dayanır (Yaralıoğlu, 2001).

AHP, karar vericinin kararını verirken kullandığı kriterleri ve alternatif seçenekleri hiyerarşik bir yapıda düzenleyerek, seçenekler arasındaki ilişkileri daha iyi anlamasını sağlamak ve karar verme sürecini daha ölçülebilir ve nesnel hale getirmektedir.

AHP yönteminde öncelikle belirlenen amaç doğrultusunda kriterler belirlenir ve bu kriterlerin birbirlerine göre önem dereceleri Çizelge 3.2’de verilen Saaty önem derecesi ölçeğine göre karar verici tarafından oluşturulur. Kriter 1’in, Kriter 2’ye göre önem

derecesi k olursa Kriter 2'nin, Kriter 1'e göre önem derecesi $1/k$ olur, başka bir ifade ile k 'nin resiprokalı (karşıtı) $1/k$ 'dir.

Çizelge 3.2. Saaty önem derecesi ölçeği (Chakraborty ve Debabrata, 2005)

Önem Derecesi	Tanım
1	Eşit Önemli
2	1-3 Arasında Ara Değer
3	Orta Derecede Önemli
4	3-5 Arasında Ara Değer
5	Kuvvetli Derecede Önemli
6	5-7 arasında ara değer
7	Çok Kuvvetli Derecede Önemli
8	7-9 arasında ara değer
9	Aşırı Derecede Önemli

Hesaplama m adet kriter için aşağıdaki adımlar izlenerek yapılabilir (Chakraborty ve Debabrata, 2005).

a) Karşılaştırma matrisi m kriter için ($m \times m$) (A) oluşturulur.

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & \dots & a_{mm} \end{bmatrix} \quad (3.1)$$

b) Her bir j sütunu, j sütununun toplamına bölünerek A_w matrisi bulunur. Bu matris normalize karşılaştırma matrisidir. Normalize karşılaştırma matrisinde her bir sütunun toplamı 1'dir.

$$A_w = \begin{bmatrix} \frac{a_{11}}{\sum a_{i1}} & \frac{a_{12}}{\sum a_{i2}} & \dots & \frac{a_{1m}}{\sum a_{im}} \\ \dots & \dots & \dots & \dots \\ \frac{a_{m1}}{\sum a_{i1}} & \frac{a_{m2}}{\sum a_{i2}} & \dots & \frac{a_{mm}}{\sum a_{im}} \end{bmatrix} \quad (3.2)$$

c) A_w matrisinin i satırının ortalamaları (c_i) hesaplanarak C sütun vektörü oluşturulur.

$$C = \begin{bmatrix} c_1 \\ c_2 \\ \dots \\ c_m \end{bmatrix} = \begin{bmatrix} \frac{a_{11}}{\sum a_{i1}} + \frac{a_{12}}{\sum a_{i2}} + \dots + \frac{a_{1m}}{\sum a_{im}} \\ \dots \\ \dots \\ \frac{a_{m1}}{\sum a_{i1}} + \frac{a_{m2}}{\sum a_{i2}} + \dots + \frac{a_{mm}}{\sum a_{im}} \end{bmatrix} \quad (3.3)$$

c_i değeri, i . kriterin önemliliğinin bağlı derecesini verir.

d) Karşılaştırma matrisindeki değerlendirmelerinin tutarlılığı kontrol edilir:

- Bunun için öncelikle $A.C$ hesaplanır.

$$A.C = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & \dots & a_{mm} \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ \dots \\ c_m \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_m \end{bmatrix} \quad (3.4)$$

- λ_{max} değeri hesaplanır. λ_{max} karşılaştırma matrisinin maksimum eigen (öz) değeridir.

$$\lambda_{max} = \frac{1}{m} \sum_{i=1}^m \frac{A.C \text{ matrisinde } i. \text{ eleman}}{C \text{ matrisinde } i. \text{ eleman}} = \frac{1}{m} \sum_{i=1}^m \frac{x_i}{c_i} \quad (3.5)$$

- Tutarlılık endeksi (CI) hesaplanır.

$$CI = \frac{\lambda_{max} - m}{m - 1} \quad (3.6)$$

- Tutarlılığın yeterli olup olmadığını incelemek için
- Çizelge 3.3'den yararlanarak Rassal İndeks (Random Index(RI)) değerleri alınır ve CI/RI değerleri karşılaştırılır. $CI/RI \leq 0,10$ ise tutarlılık derecesi uygundur, aksine $CI/RI \geq 0,10$ ise kriter değerlendirmeleri tutarsızdır bu durumda AHP anlamlı sonuç vermez.

$$CR = \frac{CI}{RI} \leq 0,10 \quad (3.7)$$

Çizelge 3.3. Rassal indeks (Chakraborty ve Debabrata, 2005)

m	2	3	4	5	6	7	8	9	10
RI	0	0.58	0.90	1.12	1.24	1.32	1.41	1.45	1.51

Tutarlılık derecesinin uygun olmaması durumunda karar vericisi kriterler arasında değerlendirmesini gözden geçirmeli başka bir ifade ile karşılaştırma matrisini yeniden oluşturmalıdır.

3.3. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi bilgisayarların doğrudan programlanmaksızın mevcut veriler arasındaki ilişkiler kurarak tahminler yapabilmesi veya kararlar alabilmesidir.

Makine öğrenimi, ürün tavsiye sistemleri, doğal dil işleme, dolandırıcılık tespiti, görüntü işleme, ses işleme, borsa ve finans gibi birçok uygulamada yer almaktadır. Günümüzde oldukça büyük miktarda verinin üretilmesi ve bu verilerin anlamlandırılarak kullanılabilir hale getirilmesi ihtiyacı nedeniyle makine öğrenmesini gittikçe vazgeçilmez kılmaktadır.

Makine öğrenmesi modellerinden bazıları aşağıda tanımlanmıştır.

- a) Denetimli Öğrenme
- b) Denetimsiz Öğrenme
- c) Pekiştirmeli Öğrenme
- d) Yarı Denetimli Öğrenme

a) Denetimli Öğrenme:

Denetimli öğrenme girdi değerlerine karşılık çıktı değerleri bilinen yani etiketli bir veri kümesinin kullanılarak bir modelin oluşturulduğu ve bu modele göre tahminlerin yapıldığı bir makine öğrenmesi türüdür. Sınıflandırma ve regresyon problemleri olarak ikiye ayrılır.

Doğrusal regresyon, lojistik regresyon, karar ağaçları, rastgele orman, destek vektör makineleri, KNN algoritmaları yaygın olarak denetimli öğrenme algoritmalarındandır.

b) Denetimsiz Öğrenme:

Denetimsiz öğrenme algoritmalarında girdi değerlerine karşılık çıktı değeri bilinmemektedir ve veriler arasındaki ilişkinin bulunması amaçlanır. Yaygın olarak kullanılan denetimsiz öğrenme yöntemleri kümelenme ve boyut azaltmadır, ilişkilendirmedir.

c) Pekiştirmeli Öğrenme:

Pekiştirmeli öğrenme sayısal ödül sinyalinin maksimize etmek için ne yapılması gerektiğini öğrenme yaklaşımıdır. Öğrenci yapması gerekenler hakkında yönlendirilmez bunun yerine hangi eylem vasıtasıyla en çok ödül elde ettiğini deneyerek keşfeder. Çoğu karmaşık problemlerde öğrencinin eylemleri mevcut adımdaki ödülün yanı sıra sonraki adımlarda elde edilecek ödülü de etkiler. Deneme/yanılma ve arama/ertelenmiş ödül kavramları pekiştirmeli öğrenmeyi diğer modellerden ayıran kavramlardır.

d) Yarı Denetimli Öğrenme:

Yarı denetimli öğrenme, denetimsiz ve denetimli öğrenmenin bir kombinasyonudur. Veri setinde etiketlenmiş veri sayısının az olmasına karşın etiketlenmemiş veri sayısının çok daha fazla olması durumunda hem denetimli öğrenme hem de denetimsiz öğrenme yetersiz kalabilir. Bu durumda az sayıdaki etiketlenmiş veri kullanılarak etiketlenmemiş veriler sınıflandırılır. Bu yöntem yarı denetimli öğrenme adı verilir. Yarı denetimli öğrenme ile denetimli öğrenme ile arasında ki en temel fark mevcut etiketlenmiş veri kümesidir. Denetimli öğrenmede etiketlenmiş veri sayısı fazla, tahmin edilmek istenen veri sayısı ise azdır. Yarı denetimli öğrenmede ise bunun tam tersi bir durum söz konusudur (Kızılkaya ve Oğuzlar, 2018).

Literatürde ve uygulamada oldukça fazla sayıda makine öğrenme algoritması bulunmaktadır. Ancak bu tez çalışmasında RO, DVM, KNN, XGBoost ve AdaBoost algoritmaları ele alınmıştır.

3.3.1. Rastgele Orman

Rastgele orman algoritması (RO), Leo Breiman ve Adele Cutler tarafından 2001 yılında geliştirilen topluluk öğrenme temelli bir denetimli öğrenme algoritmasıdır. Özellikle sınıflandırma problemlerinde başarılı sonuçlar veren algoritma regresyon problemlerinde de kullanılabilir.

Bir sınıflandırıcı yerine birden çok sınıflandırıcı üreten ve sonrasında sınıflandırıcıların tahminlerinden alınan oylarla etiketlenmemiş veriyi sınıflandıran öğrenme algoritmasıdır. Büyük veri tabanlarında eşsiz olarak çalışır ve dengesiz veri seti sınıfında hata dengeleme yöntemlerine sahiptir (Nizam ve Akın, 2014).

RO, Bagging tekniğini kullanarak birden fazla karar ağacının oluşturulmasını sağlar. Bagging, Bootstrapping ve Aggregating proseslerinin birleşimidir.

Bootstrapping prosesinde mevcut eğitim veri setinden aynı büyüklükte tekrarlı örnekleme yöntemiyle yeni bir eğitim veri seti oluşturulur. Bunun için eğitim verisinden mevcut eğitim veri seti boyutunda rastgele veriler seçilir, daha önce seçilmiş veriler tekrar seçilebilir.

Modelin eğitilmesinin ardından tahmin aşamasında her bir ağacın tahminleri toplanır ve sınıflandırma problemlerinde en çok oy alan sonuç, regresyon problemlerinde ise sonuçların ortalaması alınarak tahmin süreci tamamlanmış olur. Bu procese aggregating adı verilir.

RO algoritması geniş bir yelpazede tahmin problemlerine uygulanabilir ve optimizasyon için az sayıda parametreye sahiptir. Kullanımı kolay olmasına karşılık yanı sıra küçük örneklemlerde ve yüksek boyutlu özellik uzaylarında doğruluğu yüksektir. Kolayca paralelleştirilebilmesi dolayısıyla büyük ölçekli sistemlerde kullanılabilir (Biau ve Scornet, 2016).

3.3.2. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), Vapnik tarafından 1998 yılında önerilmiştir. Temeli istatistiksel yöntemlere dayanır. DVM, öğrenme alanında, elde edilen örüntüleri tanıma ve analiz etmede, sınıflama ve regresyon analizini kullanan güçlü bir denetimli öğrenme algoritmasıdır (Kaya ve Yıldız, 2014).

DVM'nin sahip olduğu matematiksel algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmıştır. Daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir. DVM'nin çalışma prensibi iki sınıfı birbirinden ayırabilen en ideal karar fonksiyonunun oluşturulması başka bir ifadeyle iki sınıfı birbirinden en uygun şekilde ayırabilen hiperdüzlemin tanımlanması esasına dayanmaktadır (Kavzoğlu ve Çölkesen, 2010).

DVM'ler, hiperdüzlem ile her sınıftan en yakın veri noktaları arasındaki mesafeyi maksimuma çıkarmaya çalışırlar. Hiperdüzleme en yakın noktalara destek vektörleri denir.

Hiperdüzlemi belirlemek için çekirdek fonksiyonu adı verilen matematiksel fonksiyonlar kullanılır. Literatürde birçok çekirdek fonksiyonu tanımlanmıştır. Ancak her çekirdek fonksiyonu DVM'de kullanımı uygun olmamaktadır. Uygulamada, DVM için radyal tabanlı, polinomial, lineer ve sigmoid çekirdek fonksiyonları kullanılmaktadır (Ayhan ve Erdoğan, 2014).

DVM, metin sınıflandırma, biyoinformatik, görüntü analizi ve doğal dil işleme gibi birçok alanda yaygın olarak kullanılmaktadır.

3.3.3. K-En Yakın Komşu Algoritması

K-En yakın komşu (KNN), hem sınıflandırma hem de regresyon problemleri için kullanılan parametrik olmayan bir denetimli makine öğrenmesi algoritmasıdır.

KNN algoritmasında, k değeri, tahmin yaparken kaç adet en yakın komşunun kullanılacağını ifade eden kullanıcı tanımlı bir parametredir. Sınıflandırma problemlerinde, KNN algoritmasında k adet en yakın komşuya olan mesafe çeşitli metrikler kullanılarak belirlenir. Sınıflandırılacak nesnenin, k adet en yakın komşulardan en fazla nesneye sahip olan sınıfa ait olduğuna hükmedilir.

KNN algoritması regresyon için kullanıldığında ise çıktı değerini tahmin etmek için, en yakın k adet komşu noktaların çıktı değerlerine bakılır ve bu komşuların ortalaması tahmin değeri olarak alınır.

Algoritmanın performansı k değerinin seçiminden önemli ölçüde etkilenir. Eğer k değeri küçükse, modelin karmaşıklığı artar ve aşırı uyuma (overfitting) riski artar, buna karşılık k değeri büyükse, modelin karmaşıklığı azalır ve yanlış tahminlerin oluşma riski artar. Bu nedenle, k değeri seçilirken, veri kümesinin özelliklerine ve problem türüne göre uygun bir değer seçmek önemlidir.

KNN algoritmasında komşulara olan uzaklıklar Öklid Uzaklığı Manhattan Uzaklığı, Minkowski Uzaklığı gibi metrikler kullanılarak hesaplanır.

K-NN algoritması, eğitiminin olmaması, gerçekleştiriminin kolay, analitik olarak izlenebilir, yerel bilgilere uyarlanabilir, paralel gerçekleştirime uygun, gürültülü eğitim verilerine karşı dirençli olması gibi avantajları ile sınıflandırma uygulamalarında özellikle tercih edilmektedir (Taşcı ve Onan, 2016).

Buna karşılık, yüksek miktarda bellek alanına gereksinim duyması, veri seti ve öznitelik boyutu arttıkça işlem yükünün ve maliyetin önemli ölçüde yükselmesi, performansın k komşu sayısı, uzaklık ölçütü ve öznitelik sayısı gibi parametre ve özelliklere bağlı olarak etkilenmesi gibi birtakım dezavantajları da beraberinde getirmektedir (Taşcı ve Onan, 2016)

3.3.4. XGBoost

XGBoost Tianqi Chen ve Carlos Guestrin tarafından geliştirilmiş ölçeklenebilir bir ağaç artırma algoritmasıdır.

XGBoost algoritmasının başarısının arkasındaki faktör her türlü senaryodaki ölçeklenebilir olmasıdır. Mevcut popüler çözümlerden on kattan daha hızlı çalışmakta, dağıtılmış veya bellek sınırlı ortamlarda milyarlarca örneğe ölçeklenebilir. XGBoost algoritmasının ölçeklenebilirliği birkaç önemli sistem ve algoritmik optimizasyon sayesinde gerçekleşir (Chen & Guestrin, 2016). Bu iyileştirmeler:

- Seyrek verilerin işlenmesi için yeni bir ağaç öğrenme algoritması
- Paralel ve dağıtık hesaplama ile öğrenme sürecinin hızlandırılması
- Çekirdek dışı hesaplama (out-of-core) ile veri bilimcilerin büyük veri kümelerini tek bir masaüstü bilgisayarla bile işleyebilmesi
- Tüm bu tekniklerin bir araya getirilerek daha az kaynakla daha büyük verilerin ölçeklenebilmesini sağlamaktadır.

3.3.5. AdaBoost

Adaptive Boosting veya kısaltması olarak AdaBoost 1995 yılında Yoav Freund ve Robert Schapire tarafından geliştirilmiştir. AdaBoost temel olarak zayıf sınıflandırıcıları bir araya getirerek güçlü bir sınıflandırıcı oluşturmayı amaçlar.

AdaBoost algoritması her bir iterasyonda temel öğrenci adı verilen basit bir öğrenme algoritması çağırır ve öğrenciye hatası ile ters orantılı bir ağırlık katsayısı atar. Ağırlık katsayılarına bağlı ağırlıklı oylama sonucunda çözüm elde edilir (Acılar, 2020).

AdaBoost algoritmasının hesaplama adımları aşağıdaki gibi özetlenebilir:

1. Veri kümesinin her bir örneği için eşit ağırlıklar verilir
2. Belirlenen sayıda zayıf öğrenci (genellikle karar ağaçları kullanılır) veri kümesindeki her örnek için tahmin yapar
3. Her öğrenci için hata oranı hesaplanır. Hata oranı yanlış sınıflandırılan örneklerin ağırlıklarının toplamıdır.
4. Öğrencilerin hata oranlarıyla ters orantılı olacak şekilde her öğrenci için bir ağırlık belirlenir.
5. Sonraki adımdaki öğrenciyi eğitmek için, tahminlere göre ağırlıklandırılmış veri kümesi oluşturulur. Adımlar belirli sayıda öğrenci eğitilene kadar tekrar edilir
6. Son olarak, her bir öğrencinin tahminleri ağırlıklı olarak birleştirilir ve son sınıflandırıcı elde edilir.

AdaBoost başta görüntü işleme, doğal dil işleme, pazarlama, biyoinformatik olmak üzere birçok uygulamada kullanılır.

AdaBoost algoritması, yüksek doğruluk oranları elde edebilen güçlü bir sınıflandırma algoritmasıdır. AdaBoost algoritması veri kümesindeki daha az önemli örnekleri yok saymak yerine her örnek için önemli olma şansını artırarak daha doğru sonuçlar elde edilmesini sağlar.

Ancak AdaBoost algoritmasında hiperparametrelerin uygun bir şekilde seçilmesi önemlidir bu nedenle hiperparametre optimizasyonu zordur. Ayrıca veri kümesindeki dengesiz sınıf dağılımı doğruluğu düşürebilir.



4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu çalışmanın ilk aşamasında ÇKKV yöntemlerinden AHP yöntemi kullanılarak, güneş enerjisi santralleri kurulumu için arazi seçiminde etkili olabilecek 7 kriter seçilmiş ve bu kriterlere göre Burdur ilinin arazi yapısı GES kurulumu için 4 sınıfa ayrılarak sınıflandırılmıştır.

GES kurulumu için uygun alan araştırması için seçilen 7 kriter:

1. Eğim
2. Bakı
3. Enerji Nakil Hattına Yakınlık
4. Yola Yakınlık
5. Fay Hatlarına Uzaklık
6. Arazinin Tarım Arazisi Dışında Olması
7. Arazinin Orman Arazisi Dışında Olması

Burdur ili arazisi 30 metre çözünürlüklü arazi parçalarına(piksellere) ayrılmıştır. Bu arazi parçalarının belirlenen 7 kritere göre AHP analizine göre GES yatırımına uygunluğu ele alınmıştır.

AHP analizi sonucunda arazini GES yatırımı için uygunluk durumu 4 farklı sınıfa ayrılarak etiketlenmiştir. Buna göre sonucunda elde edilen veri seti kullanılarak makine öğrenmesi yöntemlerinin performansları karşılaştırılmıştır.

4.1. AHP Analizi

AHP analizinde kriter ağırlıklarının belirlenmesi amacıyla 5 kriter için 5x5'lik karşılaştırma matrisi oluşturulmuştur.

Eğim ve bakı kriterleri için haritalar USGS'den alınan 30 metre çözünürlüklü sayısal yükseklik modeli kullanılarak QGIS yazılımıyla elde edilmiştir. Yol, enerji nakil hatları, tarım ve orman arazileri Türkiye Ulusal Coğrafi Bilgi Sistemi çevre düzeni planlarından, fay hatları MTA Genel Müdürlüğünden QGIS ortamında sayısallaştırarak elde edilmiştir.

Kriterlerin Çizelge 3.2'de verilen Saaty önem derecesi ölçeğine göre bağıl önem dereceleri karar vericinin kişisel değerlendirmesi neticesinde karşılaştırma matrisine işlenmiştir.

Karşılaştırma matrisi, satırın sütuna göre önem derecesini gösterir. Örneğin "Eğim", "Bakı"ya göre 2 kat fazla önemli değerlendirilmiştir. Buna karşılık "Bakı"nın,

“Eğim”e göre değerlendirilmesi bir önceki değerlendirmenin resiprokalidir yani 1/2'dir. Belirlenen 5 kritere göre karşılaştırma matrisi Çizelge 4.1’deki gibi oluşmuştur.

Çizelge 4.1. İkili karşılaştırma matrisi

	Enerji Nakil Hattına Yakınlık	Yola Yakınlık	Eğim	Bakı	Fay Hattına Uzaklık
Enerji Nakil Hattına Yakınlık	1	3	2	0,2	8
Yola Yakınlık	0,333	1	1	0,2	7
Eğim	0,5	1	1	0,5	7
Bakı	5	5	2	1	9
Fay Hattına Uzaklık	0,125	0,143	0,143	0,111	1

Çizelge 4.1’de oluşturulan karşılaştırma matrisine göre hesaplanan tutarlılık değeri 0,096 olarak bulunmuş ve 0,10’dan küçük olduğu için değerlendirmenin tutarlı olduğu görülmektedir.

Hesaplanan kriter ağırlıkları ise Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Kriter ağırlıkları



	Enerji Nakil Hattına Yakınlık	Yola Yakınlık	Eğim	Bakı	Fay Hattına Uzaklık	Kriter Ağırlıkları (C)
Enerji Nakil Hattına Yakınlık	0,14	0,3	0,33	0,1	0,25	0,22
Yola Yakınlık	0,05	0,1	0,16	0,1	0,22	0,13
Eğim	0,07	0,1	0,16	0,25	0,22	0,16
Bakı	0,72	0,49	0,33	0,5	0,28	0,46
Fay Hattına Uzaklık	0,02	0,01	0,02	0,06	0,03	0,03

Belirlenen kriterin ağırlığı ile ilgili kritere göre uygunluğu değerlendirilen arazi parçasının almış olduğu puan çarpılarak, kriter için skor hesaplanmıştır. Daha sonra tüm kriterler için hesaplanan kriter skorları toplanarak arazi parçasının GES için uygunluk skoru bulunmuştur.

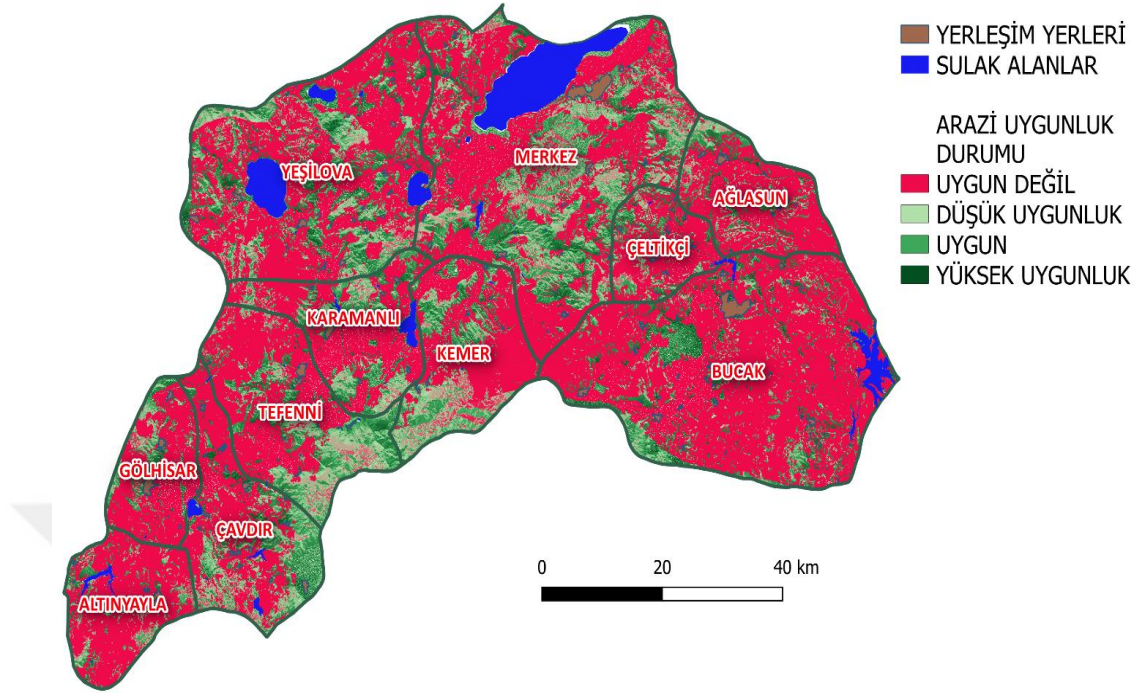
Ayrıca arazi parçasının yasal olarak GES kurulumuna izin verilmeyen tarım ve orman alanları dışında olup olmadığını denetlemek için Arazinin “Tarım Arazisi Dışında Olması” ve “Arazinin Orman Arazisi Dışında Olması” kriterleri de hesaplama dâhil edilmiştir. Bu 2 kriter boolean mantığına göre izin verilen alanlar için 1 değerini izin verilmeyen alanlar için 0 değerini almaktadır. Örneğin bir arazi parçası tarım arazi içerisinde, “Tarım Arazisi Dışında Olması” kriterine göre 0 değerini alacağından GES uygunluk skoru 0 ile çarpılarak arazi “UYGUN DEĞİL” olarak sınıflandırılır. Eğer tam tersi olarak arazi parçası tarım arazisi dışındaysa “Tarım Arazisi Dışında Olması” kriterine göre 1 değerini alacak ve GES uygunluk skoru 1 değeri ile çarpılarak başka ifade ile uygunluk skoru değişmeden, GES için uygunluk durumu belirlenmiştir.

GES uygunluk skoru değerlerine göre Çizelge 4.3’te verilen 4 farklı sınıflandırma yapılmış ve 30 metre çözünürlüklü arazi parçaları aldığı değerlere göre renklendirilerek Şekil 4.1’de verilen Burdur İli Arazi Uygunluk Haritası oluşturulmuştur.

Çizelge 4.3. GES uygunluk değerleri ve renk skalası

Değer	Uygunluk	Renk Skalası
0-2.5	Uygun Değil	
2.5-5	Düşük Uygunluk	
5-7.5	Uygun	
7.5-10	Yüksek Uygunluk	

BURDUR İLİ ARAZİ UYGUNLUK HARİTASI




Şekil 4.1. Burdur ili arazi uygunluk haritası

4.2. Makine Öğrenmesi Yöntemlerinin Karşılaştırılması

Burdur İli Arazi Uygunluk Haritası 30 metre x 30 metre boyutlarında arazi parçaları temsil eden piksellerden oluşmaktadır. Haritanın genişliği 4.850, yüksekliği 3.896 pikseldir. Dolayısıyla harita 18.895.600 adet veriden oluşmaktadır.

Bu tez çalışmasına konu olan makine öğrenmesi yöntemlerinin karşılaştırılması için Burdur İli Arazi Uygunluk Haritası üzerinde bulunan ve Şekil 4.2’te gösterilen 1200x1200 piksellik bir bölüm veri seti olarak kullanılmıştır.



Şekil 4.2. Makine öğrenmesi algoritmaları veri seti bölgesi

Veri setinde toplamda 1.444.000 adet veri bulunmaktadır. Veriler 7 özniteliğe sahip olup 4 farklı sınıftan oluşmaktadır. Verilerin sınıflara göre dağılımı Çizelge 4.4’de verilmiştir.

Çizelge 4.4. Makine öğrenmesi algoritmaları için veri dağılımı

	Veri Sayısı
Uygun Değil	932.317
Düşük Uygunluk	248.506
Uygun	170.330
Yüksek Uygunluk	88.847
TOPLAM	1.440.000

AHP yöntemi ile elde edilen değerler ile KNN, RO, DVM, XGBoost ve AdaBoost algoritmaları kullanılarak sınıflandırma işlemi yapılmıştır. Veri setindeki 475.200 adet veri test verisi olarak ayrılmıştır.

Makine öğrenmesi algoritmaları ile ilgili hesaplamalar Python programlama dili ile Scikit-Learn kütüphanesi ve XGBoost kütüphanesi ile gerçekleştirilmiştir.

KNN algoritması ile yapılan eğitim sonucunda karmaşıklık matrisi Çizelge 4.5’de verilmektedir.

Çizelge 4.5. KNN algoritması karmaşıklık matrisi

		Uygun Değil	Düşük Uygunluk	Uygun	Yüksek Uygunluk
		Gerçek Değerler			
Uygun Değil	Tahmin Değerleri	307417	5	0	0
Düşük Uygunluk		0	81858	3	0
Uygun		0	2	56422	0
Yüksek Uygunluk		0	0	0	29493

Çizelge 4.5’de görüldüğü üzere KNN algoritması 475.200 veri üzerinde 475.190 adet test verisini doğru olarak, 10 veriyi ise yanlış sınıflandırmaktadır.

RO algoritması ile yapılan eğitim sonucunda karmaşıklık matrisi Çizelge 4.6’da verilmektedir.

Çizelge 4.6. RO algoritması karmaşıklık matrisi

		Uygun Değil	Düşük Uygunluk	Uygun	Yüksek Uygunluk
		Gerçek Değerler			
Uygun Değil	Tahmin Değerleri	307418	4	0	0
Düşük Uygunluk		0	81861	0	0
Uygun		0	0	56423	1
Yüksek Uygunluk		0	0	0	29493

Çizelge 4.6’da görüldüğü üzere RO algoritması 475.200 veri üzerinde 475.195 adet test verisini doğru olarak, 5 veriyi ise yanlış sınıflandırmaktadır.

DVM algoritması ile yapılan eğitim sonucunda karmaşıklık matrisi Çizelge 4.7’de verilmektedir.

Çizelge 4.7. DVM algoritması karmaşıklık matrisi

		Uygun Değil	Düşük Uygunluk	Uygun	Yüksek Uygunluk
		Gerçek Değerler			
Uygun Değil	Tahmin Değerleri	307306	116	0	0
Düşük Uygunluk		49	81647	165	0
Uygun		0	108	56273	43
Yüksek Uygunluk		0	0	76	29417

Çizelge 4.7’de görüldüğü üzere DVM algoritması 475.200 veri üzerinde 474.643 adet test verisini doğru olarak, 557 veriyi ise yanlış sınıflandırmaktadır.

XGBoost algoritması ile yapılan eğitim sonucunda karmaşıklık matrisi Çizelge 4.8’de verilmektedir.

Çizelge 4.8. XGBOOST algoritması karmaşıklık matrisi

		Uygun Değil	Düşük Uygunluk	Uygun	Yüksek Uygunluk
		Gerçek Değerler			
Uygun Değil	Tahmin Değerleri	307416	6	0	0
Düşük Uygunluk		4	81856	1	0
Uygun		0	0	56420	4
Yüksek Uygunluk		0	0	0	29493

Çizelge 4.8’de görüldüğü üzere XGBoost algoritması 475.200 veri üzerinde 475.185 adet test verisini doğru olarak, 15 veriyi ise yanlış sınıflandırmaktadır.

AdaBoost algoritması ile yapılan eğitim sonucunda karmaşıklık matrisi Çizelge 4.9’da verilmektedir.

Çizelge 4.9. AdaBoost algoritması karmaşıklık matrisi

		Uygun Değil	Düşük Uygunluk	Uygun	Yüksek Uygunluk
		Gerçek Değerler			
Uygun Değil	Tahmin Değerleri	273043	34379	0	0
Düşük Uygunluk		0	68314	13547	0
Uygun		0	8422	48002	0
Yüksek Uygunluk		0	0	29493	0

Çizelge 4.9’da görüldüğü üzere AdaBoost algoritması 475.200 veri üzerinde 389.359 adet test verisini doğru olarak, 85.841 veriyi ise yanlış sınıflandırmıştır.

Makine öğrenme algoritmalarının performansları açısından oldukça iyi değerlere ulaşılmıştır. Çalışmada kullanılan 5 adet makine öğrenme algoritmasının performansları Çizelge 4.10’da verilmiştir.

Çizelge 4.10. Makine öğrenmesi algoritmaları performansları

	Doğru Sınıflandırılan Veri Sayısı	Yanlış Sınıflandırılan Veri Sayısı	Doğruluk (%)
KNN	475.190	10	99,998
RO	475.195	5	99,999
DVM	474.643	557	99,883
XGBoost	475.185	15	99,997
AdaBoost	389.359	85.841	81,936

5. SONUÇ VE ÖNERİLER

Ülkemiz güneş enerjisi potansiyeli açısından önemli bir konuma sahiptir. Burdur ili de coğrafi konumundan dolayı güneş enerjisinden faydalanabilme açısından önemli bir potansiyele sahiptir. Bir bölgenin coğrafi konumundan kaynaklanan güneşlenme süreleri, radyasyon dağılımının yanı sıra güneş enerjisi potansiyelinin verimli kullanabilmesi için kurulum alanlarının doğru şekilde seçilmesi gereklidir.

Güneş enerjisi santrallerin için yer seçimi amacıyla literatürde ÇKKV yöntemleri ve CBS entegrasyonu ile çalışmalar yapılmıştır. Söz konusu çalışmalarda AHP, FAHP, TOPSIS, ELECTREE gibi farklı ÇKKV yöntemleri kullanılmıştır. Yapılan çalışmalarda arazi kullanımı, karbon emisyonu azaltma potansiyeli gibi çevresel, arazi maliyetleri, yatırım maliyetleri gibi ekonomik, radyasyon miktarı, ortalama sıcaklık gibi iklimsel kriterler olmak üzere fazla sayıda kriter ele alınmıştır. Ayrıca güneş enerjisi santrallerinin yanı sıra rüzgâr, jeotermal ve hibrit santraller için ÇKKV kullanılarak yer seçimi çalışmaları yapılmıştır. Ancak yer seçimi çalışmalarında makine öğrenmesi yöntemlerinin kullanıldığı sınırlı sayıda çalışma bulunmaktadır.

Bu çalışmada güneş enerjisi kurulum alanlarının hızlı, doğru ve düşük maliyetli araçlarla belirlenebilmesi için makine öğrenmesi yöntemlerinin kullanılabilirliğinin araştırılması amacıyla 5 farklı makine öğrenme algoritması kullanılmıştır. GES kurulum maliyetini ve verimliliğini etkileyen arazinin eğimi, bakı durumu, enerji nakil hatlarına yakınlığı, yola yakınlığı, fay hatlarına uzaklığı gibi kriterlerin yanında yasal olarak GES kurulumuna izin verilmesi için orman arazisi ve tarım arazisi dışında bulunma kriterleri olmak üzere 7 kriter seçilerek, CBS ortamında AHP analizi yapılmıştır. Söz konusu 7 kriter ışığında Burdur ili arazisi GES kurulumu için uygunluk durumuna göre 4 sınıfa ayrılmıştır. Arazi uygunluk sınıflandırması sonucunda 30 metre çözünürlüklü, 4.850x3.896 piksel boyutlarında Burdur ili GES uygunluk haritası oluşturulmuştur.

Makine öğrenme algoritmalarının eğitimi ve test edilmesi için AHP analizi ile oluşturulan Burdur ili GES uygunluk haritasının 1200x1200 piksellik kısmı seçilmiş ve bu kısma ait veriler 7 kritere karşılık gelen veriler girdi verisi ve arazi uygunluk durumunu ise çıktı verisi olmak üzere bir veri seti oluşturulmuştur. Oluşturulan veri seti ile makine öğrenmesi algoritmaları eğitilmiştir. Eğitim sonuçlarına göre RO, DVM, KNN ve XGBoost algoritmaları ile %99'dan fazla doğruluk oranı elde edilmiştir. AdaBoost algoritmasının doğruluk oranı ise %82'dir.

Burdur ili için seçilen bölgede arazinin GES yatırımına uygunluk sınıflandırılması söz konusu makine öğrenmesi yöntemleri kullanılarak yüksek doğrulukla gerçekleştirilmiştir. Makine öğrenmesi algoritmalarının tahmin sonuçlarına göre kolaylıkla uygunluk haritaları oluşturulmasıyla, GES yatırım süreçlerinin en önemli ayağı olan yatırım yeri seçiminde araziye çıkma ihtiyacı en aza indirilerek, farklı arazi alternatiflerinin, zaman ve maliyet ekseninde tasarruf edilerek hızlı bir şekilde değerlendirilebilme imkânı sağlanabilmektedir. Çalışmanın sonuçları sadece güneş enerjisi yatırımları için değil, başta yenilenebilir enerji yatırımları olmak üzere farklı yatırım türleri için de makine öğrenmesi yöntemlerinin kullanılabilirliğini göstermektedir.



KAYNAKLAR

- Acılar, A. M. (2020). Adaboost. R2 Regresyon Algoritması İle Konutların Isıtma ve Soğutma Yüklerinin Tahmin Edilmesi. *EJONS International Journal on Mathematic, Engineering and Natural Sciences*, (13).
- Ayhan, S., ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İktisad ve İdari Bilimler Dergisi*, 9(1), 175-198.
- Bayraktar, F. S. (2020). Yoğunlaştırılmış Güneş Enerjisi (CSP) Uygulamaları İçin Bor Katkılı Eriyik Tuzların Termal Özelliklerinin İncelenmesi.
- Biau, G., ve Scornet, E. (2016). A Random Forest Guided Tour. *Test*, (25), 197-227.
- BP (2022). *BP Statistical Review of World Energy*. <https://www.bp.com/>
- Chakraborty, S., ve Debabrata, B. (2005). Design of a material handling equipment selection model using analytic hierarchy process. *The international journal of advanced manufacturing technology*, 28(11-12), 1237-1245.
- Chen, T., ve Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
- Choudhary, S., Pingale, S. M., ve Khare, D. (2022). Delineation of groundwater potential zones of upper Godavari sub-basin of India using bi-variate, MCDM and advanced machine learning algorithms. *Geocarto International*, 1-31.
- Dahooie, J. H., Kashan, A. H., Neini, Z. S., Vanaki, A. S., Zavadskas, E. K., Turskis, Z. (2022). A Hybrid Multi-Criteria-Decision-Making Aggregation Method and Geographic Information System for Selecting Optimal Solar Power Plants in Iran. *Energies*, 15, 2801.
- Dalbudak, E., ve Rençber, Ö. F. (2022). Çok Kriterli Karar Verme Yöntemleri Üzerine Literatür İncelemesi. *Gaziantep Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 4(1), 1-16.
- Dışişleri Bakanlığı. (Mart, 2023). Erişim adresi: <https://www.mfa.gov.tr/sub.tr.mfa?6f41190c-6742-405a-9e5a-784385301607>
- Enerji ve Tabii Kaynaklar Bakanlığı. (Mart 2023). Erişim adresi: <https://enerji.gov.tr/>
- Güngör, O., ve Akar, Ö. (2012). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 1(2), 139-146.

- Jung, S., Jeoung, J., Kang, H., Hong, T. (2021). Optimal planning of a rooftop PV system using GIS-based reinforcement learning. *Applied Energy*, 298.
- Karaatlı, M., Ömürbek, N., Budak, İ., Dağ, İ. (2015). Çok Kriterli Karar Verme Yöntemleri İle Yaşanabilir İllerin Sıralanması. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (33), 215-228.
- Kavzoğlu, T., ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 144.
- Kaya, Ç., ve Yıldız, O. (2014). Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz. *Marmara Fen Bilimleri Dergisi*, (3), 89-104.
- Kızılkaya, Y. M., ve Oğuzlar, A. (2018). Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili İle Kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*, (37), 90-98.
- Koç, E., ve Kaya, K. (2015). Enerji Kaynakları-Yenilenebilir Enerji Durumu. *Mühendis ve Makina*, 56(668), 36-47.
- Merrouni, A. A., Elalaoui, F. E., Mezrhab, A., Mezrhab, A., Ghennioui, A. (2018). Large scale PV sites selection by combining GIS and Analytical Hierarchy Process. Case study: Eastern Morocco. *Renewable Energy*, 863-873.
- Musbah, H., Ali, G., Aly, H. H., Little, T. A. (2022). Energy management using multi-criteria decision making and machine learning classification algorithms for intelligent system. *Electric Power Systems Research*, 203, 107645.
- Nizam, H., ve Akın, S. S. (2014). Sosyal Medyada Makine Öğrenmesi ile Duygu Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. *XIX. Türkiye'de İnternet Konferansı*, (s. 1(6)).
- Oğuz, Y., Karakan, A., ve Uslu, B. (2015). Afyonkarahisar'da Kurulu Olan Monokristal, Polikristal ve İnce Film güneş Panellerinin Verimliliğinin İncelenmesi. *Tesisat Mühendisliği*, (149), 47-58.
- Ozdemir, S., ve Sahin, G. (2018). Multi-Criteria Decision-Making In The Location Selection For A Solar PV power Plant Using AHP. *Measurement*, (129), 218-226.
- Shabab, A., ve Singh, M. P. (2019). *International Conference on Communication and Signal Processing*.
- Taşcı, E., ve Onan, A. (2016). K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. *Akademik Bilişim*, (s. 4-18).

Turhan, S., ve etiner, İ. (2012). Fotovoltaik Sistemlerde Performans Deęerlendirmesi.
Yaralıođlu, K. (2001). Performans Deęerlendirmede Analitik Hiyerarşı Proses. *Dokuz
Eylül Üniversitesi İktisadi İdari Bilimler Fakóltesi Dergisi*, 16(1), 129-142.

