



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

JEODEZİ VE COĞRAFI BİLGİ SİSTEMLERİ ANABİLİM DALI

**OBRUK DUYARLILIK HARİTALARININ CBS VE MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE HAZIRLANMASI: KONYA
KAPALI HAVZASI ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

İbrahim ÇETİN

DANIŞMAN

Doç. Dr. Süleyman Sefa BİLGİLİOĞLU

AKSARAY, 2024

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 222332406 numaralı Yüksek Lisans öğrencisi İbrahim ÇETİN tarafından hazırlanan “**OBRUK DUYARLILIK HARİTALARININ CBS VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HAZIRLANMASI: KONYA KAPALI HAVZASI ÖRNEĞİ**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Jeodezi ve Coğrafi Bilgi Sistemleri Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Süleyman Sefa BİLGİLİOĞLU

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Üye: Doç. Dr. Alper GÜRBÜZ

Ankara Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Üye: Dr. Öğretim Üyesi Cemil GEZGİN

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Tez Savunma Tarihi: 16/09/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Mehmet Ali HINIS

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinalliğini ve her türlü intihalden uzak olduğunu beyan ederim.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

İbrahim ÇETİN

TEŞEKKÜR

Bu çalışma esnasında mesleki bilgi birikimiyle desteğini esirgemeneyn, değerli tecrübelerini her zaman yanımda hissettiğim danışman hocam Doç. Dr. S. Sefa BİLGİLİOĞLU'na çok teşekkür ederim. Ayrıca çalışmamın gelişmesinde değerli fikirlerini esirgmeyen saygıdeğer Harita Mühendisliği Bölümü öğretim üyelerine teşekkür ediyorum.

Aksaray AFAD ailesine katıldığım ilk andan itibaren bilgi birikimi ve tecrübeleriyle desteklerini esirgemeyen Aksaray İl Afet ve Acil Durum Müdürlüğü ve personelleri ile çok değerli mesai arkadaşlarım Jeoloji Mühendisi Erkan YILDIRIM'a, Harita Mühendisi Osman KORKMAZ'a, Jeoloji Mühendisi Ramazan CANSU'ya ve Dr. Gül BİLEN'e teşekkür ederim

Hayatımın her anında yanımda olan, benim için hiçbir fedakârlığı esirgemeyen ve çalışmalarım esnasına manevi desteklerini her zaman hissettiğim canım kızım Eylül ÇETİN'e ve biricik eşim hayat arkadaşım Şeyda ÇETİN'e teşekkür ederim.

İbrahim ÇETİN
AKSARAY, 2024

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET.....	iv
ABSTRACT	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM.....	5
2.1 Çalışma Alanı	5
2.2 Obruk Envanter Haritası.....	7
2.3 Obruk Koşullandırma Faktörleri	10
2.3.1 Jeolojik faktörler.....	12
2.3.1.1 Litoloji.....	12
2.3.1.2 Volkanik formlara yakınlık.....	14
2.3.1.3 Faylara yakınlık	17
2.3.1.4 Yeraltı su seviyesi değişimi	19
2.3.1.5 Elektriksel iletkenlik	20
2.3.2 Topoğrafik faktörler.....	21
2.3.2.1 Yükseklik	22
2.3.2.2 Eğim.....	23
2.3.2.3 Bakı	24
2.3.2.4 Akarsuya yakınlık	25
2.3.2.5 Topoğrafik nemlilik indeksi (TWI)	26
2.3.2.6 Akarsu aşındırma indeksi (SPI)	27
2.3.3 İklimsel faktörler	28
2.3.3.1 Yağış	28
2.3.3.2 Sıcaklık	29
2.3.3.3 Ortalama su buhar basıncı.....	30
2.3.4 Çevresel ve antropojenik faktörler.....	31
2.3.4.1 Su yüzeylerine mesafe	31
2.3.4.2 Yollara yakınlık	32
2.3.4.3 Yerleşim alanlarına yakınlık	32
2.3.4.4 Arazi kullanımı	33
2.3.4.5 Normalize edilmiş fark bitki örtüsü indeksi (NDVI).....	34
2.3.4.6 Kuyu yoğunluğu.....	35
2.4 Faktör Seçimi	36
2.4.1 Çoklu bağılılık (Multicollinearity).....	36
2.5 Obruk Duyarlılık Modelleri.....	37
2.5.1 Yarı nicel yöntemler	38
2.5.2 Nicel yöntemler	38
2.5.2.1 Deterministik yöntemler	38
2.5.2.2 İstatistiksel yöntemler	38
2.5.2.3 Makine öğrenmesi yöntemleri	39
2.5.3 Model performansı.....	43
2.5.4 Hiperparametre optimizasyonu.....	45
2.6 Açıklanabilir Yapay Zekâ	46
3. ARAŞTIRMA BULGULARI	49

3.1 Veri Toplama ve Hazırlama	49
3.2 Faktör Seçimi	50
3.3 Modelin Oluşturulması.....	54
3.3.1 Hiperparametrelerin optimizasyonu	54
3.3.2 Modellerin performans sonuçları.....	54
3.3.3 Konya kapalı havzası obruk duyarlılık haritası	61
4. TARTIŞMA VE SONUÇLAR	64
KAYNAKLAR	67
ÖZGEÇMİŞ.....	78



YÜKSEK LİSANS TEZİ

OBRUK DUYARLILIK HARİTALARININ CBS VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HAZIRLANMASI: KONYA KAPALI HAVZASI ÖRNEĞİ

İbrahim ÇETİN

Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
Jeodezi ve Coğrafi Bilgi Sistemler Anabilim Dalı

Danışman: Doç. Dr. Süleyman Sefa BİLGİLİOĞLU

ÖZET

Obruklar, Konya Kapalı Havzasında (KKH) görülen en sık karstlaşma ürünleridir. KKH'da obruklar tarım alanları başta olmak üzere enerji hatları ile karayolu gibi altyapılar ve yerleşim yerlerini tehdit etmektedir. Obrukların zararlı etkilerini azaltmak için bu fenomenleri kontrol eden faktörlerin nerelerde oluşabileceğini bilmek gerekir. Bu tez çalışması ile obrukların hangi koşullar altında tekrar ettiği ve mekânsal olarak nerelerde olabileceği sorusuna, obruk duyarlılık haritası ile cevap aranmaktadır. Çalışma kapsamında, ortofotolar, saha çalışmaları, uydu görüntüleri ve AFAD İl Müdürlüklerinden temin edilen veriler kullanılarak elde edilen 628 obruk envanteri ile bir veri tabanı oluşturulmuştur. Obruk araştırmalarında literatürde sıklıkla kullanılan 20 koşullandırma faktörü seçilmiştir. Rastgele Orman (RF), Hafif Gradyan Artırma (LightGBM), Aşırı Gradyan Artırma (XGBoost), Uyumlandırılmış Gradyan Artırma (AdaBoost) ve Kategorik Artırma (CatBoost) olmak üzere 5 adet topluluk makine öğrenme (MÖ) modelleri ile obruk duyarlılık haritaları üretilmiştir. Tüm MÖ modelleri için %95 ve üzeri tahmin performansı elde edilmiş olup en yüksek doğruluk skoru ise rastgele orman algoritması (%97.35) olmuştur. Modelin açıklanabilmesi için SHAP değerleri kullanılmıştır. Buna göre RF modeli için en çok katkı veren faktörler; yeraltı su seviyesi değişim hızı, volkanik formlara yakınlık, kuyu yoğunluğu olarak belirlenmiştir. Ayrıca faktörlere ait kısmi bağımlılık grafikleri çizdirilerek her bir örneğin model üzerindeki etkisi ortaya konulmuştur. Üretilen obruk duyarlılık haritasına havza topraklarının yaklaşık %39'unun yüksek ve çok yüksek derece duyarlı alanlarda kaldığını göstermektedir. Bu çalışma ile üretilen havza bazında obruk duyarlılık haritası literatürde önemli bir açığı kapatarak havzada planlama faaliyetlerine altlık bir harita oluşturulduğu düşünülmektedir.

Anahtar kelimeler: CBS, Konya Kapalı Havzası, Makine Öğrenmesi, Obruk Duyarlılık Haritası.

Eylül, 2024; 78 sayfa

M.Sc. THESIS

PREPARATION OF SINKHOLE SUSCEPTIBILITY MAPS WITH CBS AND MACHINE LEARNING METHODS: THE CASE OF KONYA CLOSED BASIN

İbrahim ÇETİN

**Aksaray University
Institute of Science and Technology
Department of Geodesy and Geographic Information Systems**

Supervisor: Assoc. Prof. Dr. Süleyman Sefa BİLGİLİOĞLU

ABSTRACT

Obruks are the most common karstification products in the Konya Closed Basin (KKH). In the KKH, sinkholes threaten agricultural areas, infrastructures such as power lines and highways, and settlements. In order to reduce the harmful effects of sinkholes, it is necessary to know where the factors controlling these phenomena can occur. In this thesis, the question of under which conditions sinkholes recur and where they may occur spatially is sought to be answered with a sinkhole susceptibility map. Within the scope of the study, a database was created with 628 sinkhole inventory obtained by using orthophotos, field studies, satellite images and data obtained from AFAD Provincial Directorates. Twenty conditioning factors commonly used in the literature in sinkhole research were selected. Five ensemble machine learning (ML) models, namely Random Forest (RF), Light Gradient Boost (LightGBM), Extreme Gradient Boost (XGBoost), Adaptive Gradient Boost (AdaBoost) and Categorical Boost (CatBoost), were used to generate sinkhole susceptibility maps. Prediction performance of 95% and above was obtained for all ML models and the highest accuracy score was the random forest algorithm (97.35%). SHAP values were used to explain the model. Accordingly, the most contributing factors for the RF model were determined as groundwater level change rate, proximity to volcanic forms, and well density. In addition, partial dependency graphs of the factors were drawn to reveal the effect of each sample on the model. The produced sinkhole susceptibility map shows that approximately 39% of the basin soils are in highly and very highly susceptible areas. It is thought that the basin-based sinkhole susceptibility map produced by this study fills an important gap in the literature and provides a base map for planning activities in the basin.

Keywords: GIS, Konya Closed Basin, Machine Learning, Sinkhole Susceptibility Map.

September, 2024; 78 pages

ŞEKİLLER DİZİNİ

Şekil 2.1. Çalışma alanı haritası.....	6
Şekil 2.2.a. Aksaray ili Merkez Yeşiltepe köyünde meydana gelen obruk.	9
Şekil 2.2.b. Aksaray ili Eşkil ilçesi Merkez Eşmekaya sazlığı içerisinde saha çalışmaları ile tespit edilen ilk obruk.	9
Şekil 2.2.c. Aksaray ili Eşkil ilçesi Eşmakaya sazlığında saha çalışmaları ile tespit edilen ikinci obruk.....	10
Şekil 2.3. Literatürde kullanılan obruk duyarlılığı ile ilgili koşullandırma faktör grupları.	12
Şekil 2.4. KKH litolojik birimler.	14
Şekil 2.5. Suudi Arabistan'ın Al Issawiah bölgesinde, karstlaşmış kireçtaşının altında kalan Neojen bazaltlarında oluşan kapak kayası çökmesi obruğu.	15
Şekil 2.6. Karapınarda bulunan Meke Tuzlası Krater Gölünün GB'sında yer alan obrukların Google earth görüntüsü.....	16
Şekil 2.7. Volkanik alanlara yakınlık haritası.	17
Şekil 2.8. Faya yakınlık haritası.....	19
Şekil 2.9. Yeraltı su seviyesi değişimi.	20
Şekil 2.10. Elektriksel iletkenlik haritası.	21
Şekil 2.11. Yükseklik haritası.	23
Şekil 2.12. Eğim haritası.	24
Şekil 2.13. Bakı haritası.	25
Şekil 2.14. Akarsuya yakınlık haritası.	26
Şekil 2.15. Topoğrafik nemlilik indeksi haritası.....	27
Şekil 2.16. Akarsu aşındırma gücü indeksi.....	28
Şekil 2.17. Yağış haritası.	29
Şekil 2.18. Sıcaklık haritası.	30
Şekil 2.19. Su buhar basıncı.....	30
Şekil 2.20. Su yüzeylerine mesafe.	31
Şekil 2.21. Yola yakınlık.	32
Şekil 2.22. Yerleşim alanlarına yakınlık.....	33
Şekil 2.23. Arazi kullanımı.	34
Şekil 2.24. NDVI haritası.	35
Şekil 2.25. Kuyu yoğunluğu.	36
Şekil 2.26. GridSearchCV yöntemi, çapraz doğrulama yöntemi iş akış şeması.....	46
Şekil 3.1. Tüm koşullandırma faktörlerine ait pearson korelasyon matrisi.	52
Şekil 3.2. Yüksek korelasyona sahip faktörler çıkarıldıktan sonra oluşturulan pearson korelasyon matrisi.	53
Şekil 3.3. Algoritmalara ait hata matrislerinin karşılaştırılması.	56
Şekil 3.4. Faktör önem oranları grafiği.....	58
Şekil 3.5. Jeolojik ve iklimsel faktörlere ait kısmi bağımlılık grafikleri	59
Şekil 3.6. Çevresel ve Antropojenik faktörlere ait kısmi bağımlılık grafikleri	60
Şekil 3.7. Topoğrafik faktörlere ait kısmi bağımlılık grafikleri.....	61
Şekil 3.8. Konya kapalı havzası obruk duyarlılık haritası.	62

ÇİZELGELER DİZİNİ

Çizelge 2.1. Konya Kapalı Havzası içerisinde yer alan illerin alansal istatistikleri	7
Çizelge 2.2. Obruk envanter verilerinden örnekler.....	8
Çizelge 2.3. Literatür özeti ve koşullandırma faktörleri tablosu .	11
Çizelge 2.4. Literatür özeti ve kullanılan obruk duyarlılık modelleri.....	40
Çizelge 2.5. Sınıflandırma problemlerinde kullanılan metrikler; hassaslık, geri çağırma, doğruluk, özgüllük, kesinlik, F1-skoru ve AUC.	44
Çizelge 3.1. Obruk duyarlılık haritası için kullanılan koşullandırma faktörleri.	49
Çizelge 3.2. Koşullandırma faktörlerine ait VIF ve TOL değerleri.....	51
Çizelge 3.3. Yüksek VIF ve TOL değerlerine sahip faktörler çıkarıldıktan sonraki VIF ve TOL değerleri.....	51
Çizelge 3.4. Sınıflandırma algoritmaları ve en uyumlu hiperparametre değerleri. ...	54
Çizelge 3.5. Hiperparametre uyumlandırılması yapılmış algoritmaların hata matrislerinden hesaplanan performans sonuçları.	55
Çizelge 3.6. Koşullandırma faktörlerine ait önem oranları.....	57
Çizelge 3.7. Duyarlılık sınıflarına göre obruk envanterinin yüzdesel oranları.....	63

SİMGELER VE KISALTMALAR

AHP	Analitik Hiyerarşi Prosesi
BKB	Batı Kuzeybatı
CLC	Corine Land Cover
DEM	Digital Elevation Model
DKD	Doğu Kuzeydoğu
DSİ	Devlet Su İşleri Genel Müdürlüğü
DVM	Destek Vektör Makineleri
EC	Elektrik Conductivity
ESA	Europe Space Agency
GPS	Global Positioning System
HAVZA	Konya Kapalı Havzası
IDW	Inverse Distance Weighted Interpolation
InSAR	İnterferometrik SAR
JMO	Jeoloji Mühendisleri Odası
KFZ	Konya Fay Zonu
KKH	Konya Kapalı Havzası
LIDAR	Light Detection and Ranging
MÖ	Makine Öğrenimi
MÖA	Makine Öğrenimi Algoritmaları
NDVI	Normalize Edilmiş Bitki Örtüsü Fark İndeksi
PH	Hidrojen iyon Konsantrasyonu
RF	Random Forest
SPI	Akarsu Aşındırma Güç İndeksi
TGFZ	Tuz Gölü Fay Zonu
TOL	Tolerans
TWI	Topoğrafik Nemlilik İndeksi
VIF	Varyans Inflation Factor

1. GİRİŞ

Türk Dil Kurumuna göre obruk sözcüğü, yeraltı suyunun karbondioksit ile tepkimeye girmesiyle oluşan karbonik asitin toprağın çökmesi ile oluşan derin, doğal çukurluk veya doğal kuyular olarak tanımlanmaktadır. Obruklar, karstik arazilerde temsil edilen en tipik yeryüzü şekillerinden biri olup diğer afetler gibi jeolojik bir tehlike olarak değil bir jeolojik fenomen olarak kabul edilmektedir (Bui vd., 2018). Bu yapılar zeminin çözünmesi ya da karstlaşması sonucu oluşabilir. Karstlaşma, çözünebilir nitelikte kireçtaşı, dolomit marn gibi karbonatlı kayalar ile anhidrit, kalsit, halit, jips ve tuz gibi evaporitik kayaların binlerce ya da onbinlerce yıl süren fiziksel ve kimyasal süreç sonucunda oluşan jeomorfolojik bir süreçtir. Karstlaşma sürecinde, karbonik asitçe zengin yağmur suları yeraltına süzülerek karbonatlı kayaları aşındırır ve bu süreç sonucunda ise mağara sistemleri ve obruklar gibi karst ürünleri ortaya çıkar (Williams, 2008). Gutierrez vd. (2008a) tarafından obruklar, ana çökme süreci ve çöken malzeme türüne göre; çökme, sarkma ve boğulma olmak üzere 3 grupta sınıflandırmışlardır. Örtü çökmesi, konsolide olmayan artık toprak malzemenin deformasyona uğrayarak çökmesidir. Boğulma, örtü malzemesinin yeraltındaki karstik boşluklardan aşağı doğru hareket ederek çökmesi ve sarkma, çökelen malzemelerin aşağı doğru belirgin bir biçimde sünmesi olarak tanımlanabilir.

Dünya genelinde obruklar, arazi kullanımı, toprak yapısı ve su kaynaklarının yanlış kullanımı nedeniyle önemli bir sorun haline gelmiştir (Gutiérrez, 2016). Obruk oluşumuyla ilgili literatürde yapılan kapsamlı araştırmalar, çevresel ve antropojenik etkinin obruk oluşumunu hızlandırdığı tezi üzerinde yoğunlaşmışlardır. Örneğin arazi kullanımı, yeraltı suyunun aşırı kullanımı, kuyu yoğunluğu, yoğun tarımsal faaliyetler vb. gibi antropojenik faktörler dünyada pekçok yerde obrukların oluşum sıklıklarını artırmaktadır (Galve vd., 2009a; Günay vd., 2011; Ke vd., 2017; Wu vd., 2018). Kurak ve yarı kurak iklime sahip bölgeler, obrukların en sık görüldüğü sahalardır (Taheri vd., 2019). Bu alanlarda yeraltı suyunun aşırı kullanımı nedeniyle yeraltı su tablasındaki aşırı düşüş yeraltındaki hidrostatik dengenin bozulmasına sebep olur. Bozulan hidrostatik denge nedeniyle yeraltı suyu basıncı değişerek, sedimanların sıkışarak sertleşmesine sağlar ve zamanla yeraltında çöküntülere ya da obruk oluşmasına neden olur (Yechieli vd., 2016). İklim değişikliği nedeniyle yağışların azalması ile kuraklığın artmaktadır. Buna paralel olarak yeraltı suyuna karşı ihtiyaçta

artmaktadır (Sarı ve Yalçın, 2023). Bu durum ise özellikle tarımsal faaliyetlerin yoğun olduğu sahalarda ruhsatsız kuyuların artması ve dolayısıyla yeraltı suyunun baskılanmasına sebep olur (Başçiftçi vd., 2013).

Obruklar, yoğun olarak bulunduğu karstik bölgelerde binalar, karayolu, kanalizasyon vb. alt ve üst yapı sistemlerine çok ciddi zararlar verebilirler (Calligaris vd., 2017). Obruklar meydana getirdiği zararları en aza indirmek için bu fenomenlere neden olan faktörleri incelemek ve bunların mekansal dağılımlarını tahmin etmeyi amaçlayan yöntemler önem taşımaktadır (Taheri vd., 2019). Literatürde obrukların mekansal olarak haritalanması ve tespiti için; hava ve uydu görüntüleri (Esposito vd., 2021; Zhang vd., 2023), topoğrafik haritalar (Gutiérrez vd., 2008a), saha çalışmaları (Caramanna vd., 2008), çökme hasarı haritaları (Gutiérrez vd., 2008b), paleokarst analizleri (Gutiérrez vd., 2008a; Gutiérrez vd., 2008b), LIDAR (Admassu ve Woodruff, 2021; Kim vd., 2019), InSAR yöntemleri (Bianchini vd., 2022; Chai vd., 2024; Gezin, 2022; Nefeslioglu vd., 2021; Yechieli vd., 2016) ve hidrokimyasal analizler (Acero vd., 2015; Günay vd., 2011; Taheri vd., 2021) gibi yüzey araştırma teknikleri ile jeolojik (Brinkmann vd., 2008; Song vd., 2012), jeoteknik (Bausilio vd., 2022; Drobinina vd., 2020; Elmahdy ve Mostafa, 2013), jeofizik (Abelson vd., 2003; Elmahdy ve Mostafa 2013; Gutiérrez vd., 2008a; Taheri vd., 2021) ve hendekler (Gutiérrez vd., 2008b) gibi yeraltı araştırma teknikleri mevcuttur. Son yıllarda araştırmalar, duyarlılık ve tehlike haritaları gibi yöntemler üzerinde yoğunlaşmıştır. Duyarlılık modelleme ve haritalama amaçlı yaklaşımlardan ilki, sezgisel bir yaklaşım modeli olan ve uzman görüşlerine dayalı duyarlılık modelleridir. Bu modellerin tekrarlanmasındaki güçlükler, duyarlılık sınırlarını doğrulamak için nesnel bir yaklaşım bulunmaması gibi önemli temel dezavantajları bulunmaktadır. Bazı araştırmacılar bu modellerde belirli bir eşik değerler oluşturarak bir karar ağacı modeli kullanırken (Gao ve Alexander, 2008) çoğunlukla bir grup koşullandırma faktörüne dayalı puanlanlama yada ağırlıklandırma sistemi uygulamışlardır (Bilgilioğlu ve Bilgilioğlu, 2023; Bruno vd., 2008; Elmahdy ve Mostafa, 2013; Galve vd., 2009b; Hyland vd., 2006; Karaguzel vd., 2020; Qiu vd., 2020; Rosdi vd., 2017; Sarı vd., 2021; Taheri vd., 2015; Todd ve Ivey-Burden, 2016). Bazı araştırmacılar ise çeşitli matematiksel fonksiyonlar ([Olumluluk fonksiyonu; Galve vd. (2009), frekans oranı (Arabameri vd., 2020; Kim vd., 2020; Özdemir, 2015b), kanıtsal inanç fonksiyonu

(Pradhan vd., 2014]) gibi obruk olay sayısı ve koşullandırma faktörleri arasındaki ilişkiyi inceleyen istatistiksel modeller kullanılmışlardır.

Obruk dahil tüm afet duyarlılık haritalarında kullanılmaya başlayan bir diğer yaklaşım ise son yıllarda her alanda popüleritesini artıran yapay zeka alt dalı olan makine öğrenme (MÖ) modelleridir. İstatistiksel yaklaşımlarda, üretilen modeldeki veri kalitesi ve miktarına bağlı olarak birçok belirsizlik içermesi, yöntemin doğası gereği belirli bir varsayıma dayanarak verilerin modellenmesi, modeldeki tahmin kabiliyetini ve verimliliğini sınırlamaktadır (Arabameri vd., 2020). Ancak MÖ modelleri bunun aksine daha az varsayım içererek veriye dayalı karmaşık ilişkileri öğrenir ve modeller. Böylece veriye dayalı öğrenme ile yüksek verimliliğe ve tahmin kabiliyetine sahip bir model oluşturulmaktadır (Tien Bui vd., 2016). Literatür incelendiğinde MÖ modelleri heyelan (Pourghasemi vd., 2013; Sun vd., 2023), kaya düşmesi (Fanos vd., 2018, 2020), sel/taşkın (Rahman vd., 2021; Singha vd., 2024) ve çığ (Cetinkaya ve Kocaman, 2022; Cheng vd., 2024) gibi afet araştırmalarında çok sık kullanılmıştır. Obruk duyarlılık haritalarının oluşturulmasında ise MÖ modellerinin [(Rastgele Orman (RF) (Bausilio vd., 2022; Elmahdy vd., 2022), Lojistik Regresyon (LR) (Kim vd., 2018; Ozdemir, 2016), Naif Bayes (NB) (Taheri vd., 2019), Destek Vektör Makineleri (DVM), (Amin vd., 2023), Yapay Sinir Ağları (YSA) (Nefeslioglu vd., 2021), Uyumlandırılmış Gradyan Artırma Modeli (AdaBoost), Aşırı Gradyan artırma (XGBoost) ve Hafif Gradyan Artırma (LightGBM) (Arık vd., 2023)] kullanım alanı daha kısıtlıdır.

Türkiyede obruk olaylarının en sık görüldüğü bölge Konya Kapalı Havzası (KKH)'dır (AFAD, 2023). Özellikle havza bazında obrukların sayısı gün geçtikçe artarak yerleşim yerlerini tehdit eder hale gelmiştir (Günay vd., 2011; Orhan vd., 2020a; Sarı, 2017). Bu fenomenler, özellikle Karapınar (Konya)-Eskil (Aksaray) arasında yaygın bir şekilde görülmekte olup son yıllarda ise Altınekin, Çumra ve Kadınhanı bölgelerinde de güncel obruk oluşumlarına rastlanılmaktadır (Ayday ve Alan, 2020). KKH genellikle araştırmacılar, lokal olarak obrukların en çok gözlemlendiği Karapınar ve çevresinde yoğunlaşmaktadır (Coşkun vd., 2021; Özdemir, 2016; Sarı ve Yalçın, 2023). Konya Karapınar ve çevresi civarında yoğunlaşan obruklar günümüzde Karaman, Aksaray illeri başta olmak üzere tüm KKH bazında gözlemlenmeye başlanmıştır (Bilgilioglu ve Bilgilioglu, 2023). KKH bazında obruk

arařtırmalarının tamamı lokal olarak ele alınmıřtır. Havza bütününde obruk duyarlılık modelleme alıřmasının yapılmamıř olması literatürde önemli bir boşluk oluřturmaktadır.

Bu tez alıřması kapsamında KKH bütününde obruk duyarlılık modeli üretilerek, yukarıda belirtilen literatürdeki boşluğun giderilmesi amaçlanmıřtır. Obruk duyarlılık modelinin üretilmesi amacı ile 20 adet kořullandırma faktörü seilmiřtir. Bunlar; yükseklik, bakı, ortalama sıcaklık, ortalama yaėıř, volkanik formlara yakınlık, litoloji, su yüzeylerine yakınlık, yerleřime yakınlık, ortalama su buhar basıncı, arazi kullanımı, yola yakınlık, eğim, kuyu yoğunluėu, faya yakınlık, akarsuya yakınlık, yeraltı su seviyesi hızı deėiřimi, normalize edilmiř fark bitki örtüsü indeksi (NDVI), topoėrafik nemlilik indeksi (TWI), akarsu aşındırma gücü indeksi (SPI), elektriksel iletkenliktir. Volkanik formlara yakınlık obruk oluřumunda önemli bir faktör olmasına raėmen obruk modelleme alıřmalarında ilk defa bu tezde kullanılmıřtır. Bu kriterin ilk defa kullanılıyor olması tezin önemli bir diėer özgün deėeridir. Ayrıca, MÖ modellerinin obruk duyarlılık modellemesinde kullanılması ve model performans karřılařtırması ile ilgili literatürde kısıtlı alıřmalar bulunmaktadır. Bu tez alıřması kapsamında, obruk duyarlılık modellemesi için RF, XGBoost, LighGBM, CatBoost ve AdaBoost olmak üzere 5 topluluk öğrenme modelini kullanılmıř ve model performanslarının karřılařtırılmıř olması tezin bir diėer önemli özgün deėeridir.

Bu tez alıřması kapsamında literatür arařtırması sonucunda belirlenen 20 kořullandırma faktörü, pearson korelasyon matrisi, Varyans Enflasyon Faktörü (VIF) ve Tolerans (TOL) gibi faktör seiminde kullanılan istatistik temelli ölçütler kullanılarak 18'e düşürölmüřtür. Daha sonra bu faktörler kullanılarak topluluk öğrenme MÖ modelleri kullanılarak duyarlılık haritaları oluřturuldu. Obruk duyarlılık modelini açıklamak amacıyla SHapley Additive exPlanations (SHAP) yaklařımı kullanılmıřtır. Faktörlere ait kısmi baėımlılık grafikleri çizdirilerek her bir örneėin model üzerindeki katkısı ortaya konulmuřtur.

2. MATERYAL VE YÖNTEM

Heyelan, kaya düşmesi çığ, sel ve su baskınları, obruk vb. afetlerin meydana getirdiği zararları azaltmak, can ve mal kaybını önlemek amacıyla bir afet risk yönetim sistemine ihtiyaç duyulmaktadır. Duyarlılık, tehlike ve risk değerlendirmesi yapmak ise bu sistemin temel bileşenleridir. Duyarlılık, belirli bir bölgenin afet oluşumuna yatkınlığını ifade eder. Bu yatkınlık bölgenin jeolojik, hidrojeolojik topoğrafik, çevresel ve antropojenik özellikleri ile ilişkilidir. Tehlike, afetin meydana gelme olasılığı ve potansiyel etkilerini ifade ederken Risk ise tehlikenin var olduğu alanlardaki alt ve üst yapı sistemleri ve insanların zarar görme olasılığını ve boyutunu ifade eder. Doğa ve insan kaynaklı afet olaylarının meydana gelme olasılığını anlamak tehlike ve risklerini öngörmek için duyarlılık kavramı çok önemlidir. Duyarlılık haritaları ile afetlerin meydana gelme potansiyelini anlamak, etkilenebilecek bölgelerin önceden tespit edilmesini sağlar. Bu bilgi, risklerin azaltılması, yerleşim ve altyapı planlaması, acil durum yönetimi ve önleyici tedbirlerin alınması için kritik rol oynar.

Bu tez çalışması kapsamında obruk duyarlılık haritasının oluşturulması için topluluk öğrenme MÖ modelleri kullanılmıştır. Bu kapsamda saha ve arşiv çalışmaları ile 628 obruk envanteri toplanmıştır. Literatürde sıklıkla kullanılan topoğrafik, jeolojik, hidrolojik, çevresel ve antropojenik faktörler değerlendirilerek 20 koşullandırma faktörü seçilmiştir. Seçilen Faktörlerin oluşturulacak modele katkısını belirlemek ve çoklu bağlılık problemlerini ortaya çıkarmak için faktör seçimi yapılmış ve çoklu bağlılık problemine sahip 2 faktör (Su buhar basıncı ve sıcaklık) veri setinden çıkartılmıştır. Daha sonra MÖ modelleri uygulanarak obruk duyarlılık haritası oluşturulmuştur. Obruk duyarlılık modelinin açıklanması için SHAP (SHapley Additive ExPlanations) yaklaşımı benimsenmiştir. SHAP ile her bir faktörün modele olan katkısı belirlenmiştir.

2.1 Çalışma Alanı

Çalışma alanı olarak seçilen KKH, Türkiye'nin 36°53'-39°29' kuzey enlemleri ile 31°07'-35°03' doğu boylamları arasında yer almaktadır (SYGM, 2018). Yüzölçüm olarak Türkiye'nin 4.980.534 ha alan ile %7'sini takabül eden ve çok büyük bir alan olan havzanın kuzeyinde Kızılırmak ve Sakarya, Güneyinde Doğu Akdeniz, batıda

KONYA KAPALI HAVZASI

Açıklamalar

- ▲ İlçeler
- İller
- Obruk

Yükseklik

3453
Adana

927

0 35 70 140 210 280 km

31°0'0"E 32°0'0"E 33°0'0"E 34°0'0"E 35°0'0"E 36°0'0"E

39°0'0"N 38°0'0"N 37°0'0"N

Sekil 2.1. Çalışma alanı haritası.

Havza içerisinde; Aksaray, Ankara, Antalya, Isparta, Mersin, Karaman, Konya, Nevşehir ve Niğde illeri yer almaktadır. Ankara, Antalya, Isparta ve Mersin illerinin KKH sınırlarına sadece %8'lik kısmı girmektedir. KKH'da yer alan illerin yüzölçümlerine göre kapladığı alanlar incelendiğinde sırasıyla Konya, Aksaray ve Karaman illeri en fazla yer kaplamaktayken Antalya ve Mersin illeri en az alanları kaplamaktadırlar. Toplam il alanının havza alanına göre dağılımı incelendiğinde sırasıyla Aksaray, Konya ve Karaman illeri ilk 3 sırayı almaktadır (Çizelge 2.1).

Çizelge 2.1. Konya Kapalı Havzası içerisinde yer alan illerin alansal istatistikleri (SYGM, 2018).

İller	Toplam Alan (Ha)	İlin Havza İçindeki Alanı (Ha)	Havza Alanının İllere Göre Dağılımı (%)	İl Alanının Havzaya Giren Kısım (%)
Aksaray	799.700	682.879	14	85
Ankara	3.071.500	213.963	4	7
Antalya	2.072.300	33.690	1	2
Isparta	893.300	123.978	2	14
Mersin	1.585.300	35.405	1	2
Konya	3.825.700	2.810.988	56	73
Karaman	959.000	572.668	12	60
Nevşehir	546.700	64.619	1	12
Niğde	1.429.400	440.467	9	31

KKH genel itibariyle plato ve ovalar ile sınırlanmaktadır. Havzanın kuzey ve kuzeybatısında Aladağlar, Sultandağları, Lora ve Eşenler Dağları, güney sınırında ise Toros dağları ile sınırlanan Beyşehir Gölü alt havzası yer almaktadır (URL-1). Karacadağ, Erenler Dağı, Takkeli Dağ ve Hasan Dağı gibi volkanik kütleler havzanın güney sınırından doğusuna doğru paralel bir çizgisellikle yükselmektedir. Konya ve Ereğli ovası en geniş alana sahip ovaları olup Çumra, Karapınar, Beyşehir, Doğanhisar, Altınekin, Aksaray ve Seydişehir ovalarında havza sınırları içerisinde yer almaktadır. Havzanın %56'sı tarım alanından %37'si orman ve yarı doğal alanlardan %4'ü yer üstü sularından %2'si yapay alanlardan ve %1'ise sulak alanlardan oluşmaktadır (SYGM, 2018).

Havzada ortalama sıcaklık 0 ile 12.5 °C arasında değişmekte olup en soğuk ay Ocak ayı; ortalama -0.3 °C ve en sıcak ay ise Temmuz; ortalama 23.4 °C olarak ölçülmüştür (SYGM, 2018). Havza'nın büyük bir bölümünde yarı kurak- kurak iklim egemen olup ülkemizde yağışların en az düştüğü bölgedir. Havza alanının büyüklüğü sebebiyle güneyinde akdeniz iklimi görülürken kuzey kesimlerinde karasal iklim, orta kesimlerde çöl iklimi görülmektedir. Havzaya en fazla yağış, ilkbahar aylarında konveksiyonel yağışlar şeklinde ortalama 27-61 mm arasında değişen miktarlarda düşmektedir.

2.2 Obruk Envanter Haritası

Obruklar, elektrik, su ve kanalizasyon gibi altyapıları, karayolu, demiryolu gibi üst yapıları tehdit eden fenomenlerdir. Obrukların zararlarını azaltmak için ilk adım bu

fenomenlerin nerelerde olabileceğini tahmin etmektir. Bu sebeple obruk duyarlılık haritaları kullanılmaktadır. Duyarlılık çalışmalarında temel amaç, obruklar ile obruk oluşumuna etki eden koşullandırma faktörleri arasındaki ilişkiden yola çıkarak çalışma alanının özelliklerini ortaya çıkarmaktır. Obruk envanter haritaları, bu nedenle duyarlılık haritalarının oluşumunda kritik bir öneme sahiptir (Gutierrez, 2016).

Obruk modellemesinde obruk olmayan yerlerin de, obruk olan alanlarla birlikte veri tabanına dâhil edilmesi gerekmektedir. Bu nedenle çalışma alanını homojen olarak kapsayan ve rastgele olarak belirlenen obruk olmayan alanlar veri tabanına dâhil edilmiştir. KKH’da obruk oluşumu Konya, Aksaray ve Karaman’da yoğunlaşmaktadır. Bu tez çalışmasında 609 adet arşiv kayıtları 11 adet saha çalışmaları ve 8 adet ise uydu görüntüleri olmak üzere toplam 628 obruk envanteri ve kayıt altına alınarak bir veri tabanına eklenmiştir (Çizelge 2.2, Şekil 2.2a, Şekil 2.2b, Şekil 2.2c).

Çizelge 2.2. Obruk envanter verilerinden örnekler.

S. No	İli	İlçesi	Köy/Belde	Tarihi	Çap	Derinlik (m)
1	Karaman	Merkez	Akçaşehir	2017	25	8
2	Karaman	Merkez	Akçaşehir	2016	60	0
3	Karaman	Ayrancı	Ambar	2020	5	4
4	Karaman	Merkez	Süleymanhacı	2018	—	—
5	Konya	Karapınar	Fevzi paşa	2019	6.5	10
6	Konya	Karapına	Reşadiye	2019	5	14
7	Konya	Karapına	Reşadiye	2019	30	6.6
8	Karaman	Merkez	Akçaşehir	2022	40	20
9	Aksaray	Sultanhanı	Gazi Mahallesi	2021	47	1
10	Aksaray	Eskil	Güneşli	2015	25	10
11	Aksaray	Eskil	Güneşli	2022	8	3
12	Aksaray	Eskil	Gümüşdüğün	2022	10	6



Şekil 2.2.a. Aksaray ili Merkez Yeşiltepe köyünde meydana gelen obruk.



Şekil 2.2.b. Aksaray ili Eşkil ilçesi Merkez Eşmekaya sazlığı içerisinde saha çalışmaları ile tespit edilen ilk obruk.



Şekil 2.2.c. Aksaray ili Eskişehir ilçesi Eşmakaya sazlığında saha çalışmaları ile tespit edilen ikinci obruk.

2.3 Obruk Koşullandırma Faktörleri


Obrukların oluşmasında etkili olan çok sayıda birbiriyle ilişki parametreler bulunmaktadır (Wu vd., 2018; Xie., 2022). Bu faktörlerle ilgili literatürde yaygın olarak kullanılan kabul görmüş bir kural bulunmamaktadır (Galve vd., 2008). Bu amaçla literatürde kullanılan yöntemler ve koşullandırma faktörlerinin incelenmesi obruk duyarlılık haritası için yol gösterici bir adımdır. Koşullandırma faktörlerini belirlemek amacıyla literatürde obruk ile ilgili 74 adet makele (SCI-E, ESCI ve TR Dizin kapsamında taranan dergilerde yayınlanmış) incelenmiştir. Bu çalışmalarda faktörler, hidrolojik, topoğrafik, jeolojik, iklimsel ve çevresel-antropojenik olmak üzere 5 ana başlık altında toplanmış olup Çizelge 2.3'te faktör gruplarından bazı örnekler yer almaktadır.

Çizelge 2.3. Literatür özeti ve koşullandırma faktörleri tablosu.

Kaynak	JEOLJİK							TOPOĞRAFİK										İKLİM				ÇEVRESEL VE ANTROPOJENİK							
	J 1	J 2	J 3	J 4	J 5	J 6	J D	T 1	T 2	T 3	T 4	T 5	T 6	T 7	T 8	T 9	T D	İ 1	İ 2	İ 3	İ D	Ç 1	Ç 2	Ç 3	Ç 4	Ç 5	Ç 6	Ç 7	Ç D
Amin vd., 2023					X		X	X	X																				
Arik vd., 2023	X	X		X	X		X	X	X	X	X	X	X	X	X	X		X	X	X		X	X	X	X				X
Ayday ve Alan 2020	X																												
Bausilio vd., 2022	X		X	X	X																				X				
Bianchini vd., 2019		X	X																			X							
Bianchini vd., 2022	X	X		X																		X							
Boualla vd., 2016	X						X	X	X	X								X	X										
Bruno vd., 2008	X																												
Calligaris vd., 2017		X												X								X							
Ciotoli, vd., 2015	X		X																										X
Doctor ve Doctor, 2012		X		X																								X	
Elmahdy ve Mostafa, 2013	X							X																				X	
Esposito vd., 2021	X		X																										
Galve, vd., 2009			X	X	X			X	X	X												X							
Galve, vd., 2008	X		X	X	X			X	X	X			X																

J1: litoloji, J2: Fay, J3: Tabaka Kalınlığı, J4: Yeraltı Su Seviyesi, J5: Hidrojeoloji, J6:Geçirgenlik, JD: Diğer jeolojik faktörler, T1: Yükseklik, T2: Eğim, T3: Bakı, T4: Plan Eğriliği, T5: Profil Eğriliği, T6: Eğrilik, T7: Akarsuya yakınlık T8: Topoğrafik Nemlilik İndeksi, T9: Akarsu Aşındırma Gücü İndeksi, TD: Diğer Topoğrafik Faktörler, İ1: Yağış, İ2: Sıcaklık, İ3: Su Buhar Basıncı, İD: Diğer İklimsel Faktörler, Ç1: Arazi Kullanımı, Ç2: Kuyu Yoğunluğu, Ç3: Yerleşime Yerleri, Ç4: Yollar, Ç5: NDVI, Ç6:Toprak Tipi, Ç7: Su Yüzeylerine Yakınlık, ÇD: Diğer Çevresel Faktörler

Topoğrafik faktörlerden; yükseklik, eğim ve bakı, Jeolojik parametrelerden; litoloji, faylara yakınlık ve örtü kalınlığı, çevresel-antropojenik parametrelerden; arazi kullanımı, kuyu yoğunluğu ve yollara yakınlık, iklim parametrelerinden; yağış ve sıcaklık, hidrolojik faktörlerden; yeraltı suyu seviyesi değişimi, geçirgenlik ve PH gibi parametreler literatürde en çok kullanılan faktörlerdir (Şekil 2.3).



Şekil 2.3. Literatürde kullanılan obruk duyarlılığı ile ilgili koşullandırma faktör grupları.

Bu tez çalışması kapsamında; yükseklik, bakı, ortalama sıcaklık, ortalama yağış, volkanik formlara yakınlık, litoloji, su yüzeylerine yakınlık, yerleşime yakınlık, ortalama su buhar basıncı, arazi kullanımı, yola yakınlık, eğim, kuyu yoğunluğu, faya yakınlık, akarsuya yakınlık, yeraltı su seviyesi hızı değişimi, NDVI) TWI, SPI ve elektriksel iletkenlik olmak üzere 20 koşullandırma faktörü oluşturulmuştur. Her bir faktör için projeksiyon ve datum bilgileri; Dünya Jeodezik Sistemi 1984 (WGS 1984), 36. Bölge seçilmiş ve 20 metre çözünürlükte üretilmişlerdir.

2.3.1 Jeolojik faktörler

Bu tez çalışması kapsamında obruk duyarlılık haritası için seçilen litoloji, faylara yakınlık ve volkanik formlara yakınlık faktörleri gibi jeolojik kökenli ile yeraltı suyu değişim hızı ve elektriksel iletkenlik faktörleri gibi hidrojeolojik kökenli veriler kullanılmıştır.

2.3.1.1 Litoloji


Obruk oluşumu, litoloji ve tektonizma ile doğrudan ilişkilidir. KKH'da bu çerçevede litolojik ve tektonik özellikleri çerçevesinde karstlaşmaya son derece uygun bir yapıdadır (Günay vd., 2011). Obrukların jeolojik yapısı, ana kaya olarak karbonatlı kayaların ve evaporitlerin karstlaşması ile karstik olmayan örtü tabakasını etkileyen çözünme kaynaklı çökme süreçleri olarak iki grupta şekillenebilir (Ciotoli vd., 2016).

KKH'da karstlaşma, Neojen yaşlı gölssel karbonatlarda gelişmektedir (Türk vd., 2012). Türk vd. (2012)'e göre obruklar, her ne kadar Neojen yaşlı kayalarda gözlene de aslında örtülü olarak korunan Mezozoik yaşlı kireçtaşlarında gelişen karst sisteminden kaynaklandığını ifade etmektedir. Bu birimlerin arasında geçirimsiz tabakalar mevcuttur. Bu tabakalar, yeraltı suyunun akışını dolayısıyla hidrolojik süreçleri ve karstlaşmayı etkilemektedir (Acero vd., 2015). Erol (1985) Mezozoyik kireçtaşlarında başlayan karstlaşmanın Kuvaterner'e kadar devam ettiği, bu dönemde ise göllerin kuruyarak oluşan bir aşınma yüzeyi oluşturduğunu belirterek nehirlerin olası akışlarının KKH'dan Tuzgölü Havzası'na doğru olduğunu belirtmiştir.

KKH'da çok geniş bir alanda yayılım gösteren kireçtaşı marn jips ve traverten gibi karbonatlı kayalar yukarıda da değinildiği üzere geniş bir yaş aralığında yer almaktadır. Kuvaterner yaşlı travertenlere, Konya Ereğli ilçesi Akhüyük köyü civarında, Seydişehir ilçesinin kuzeybatısında, Hadim ilçesi Göksü nehri civarında ve Cihanbeyli ilçesinin güneyinde çok az bir alanda rastlanır (Polat, 2011). Pliyosen ve Eosen yaş aralığında bulunan karbonatlar ise havzanın güneyinde Karaman Ayrancı ilçesinin kuzeyi ile Konya Derebucak ilçesinde çok küçük bir alanda ince bir sırt şeklinde yayılım göstermektedir (Şekil 2.4).

Obrukların en fazla görüldüğü litolojik grup olan Neojen yaşlı karbonatlı-kırıntılı kayalar, aynı zamanda KKH'da en fazla alan kaplayan ikinci büyük litolojik gruptur. Neojen yaşlı jips, marn, killi kireçtaşı, kumtaşı ve çamurtaşı gibi kayaları ile üste doğru gölssel tabakalı bol erime boşluklu ve ara ara organik maddece zengin killi kireçtaşlarını içeren birim İnsuyu Formasyonu olarak adlandırılmaktadır (Ulu vd., 1994). Bu kayalar, Konya'nın kuzeybatısında Altınekin'den başlayarak Aksaray İli Eski ve Sultanhanı ilçeleri ile Konya'nın Karapınar ve Emirgazi ilçeleri arasında yer alan geniş bir alanda yayılım göstermektedirler (Özdemir, 2015a). Neojen yaşlı kireçtaşı, kiltası ve marn içerikli kayalar ise Karaman ili Kâzımkarabekir, Konya İli Akören ve Çumra ilçesinin güneyi ile Derbent, Beyşehir ve Hüyük ilçelerini de kapsayan geniş bir alanda görülmektedir. Oligosen yaşlı kumtaşı, kiltası ve konglomera ile yer yer jipsli birimleri içeren kırıntılı ve Paleojen yaşlı karbonatlı kayalar Konya'nın Ereğli ilçesinin çok küçük bir bölümünde, Cihanbeyli ilçesinin kuzeybatısında ve Tuz Gölü'nün kuzeydoğusunda Şereflikoçhisar ilçesi sınırları içerisinde kalan küçük bir alanda yüzlek vermektedir (Şekil 2.4).

Tez kapsamında kullanılan litoloji verisi için MTA tarafından üretilen 1/25000 ölçekli Aksaray, Antalya, Konya, Niğde, Nevşehir, Isparta, Mersin, Karaman illerine ait jeoloji haritaları koordinat dönüşümleri yapılarak birleştirildikten sonra havza sınırına göre kesilmiştir. Daha sonra elde edilen harita, yaş ve litolojik özellikleri gözetilerek yeniden sınıflandırılmıştır (Şekil 2.4).



Şekil 2.4. KKH litolojik birimler.

2.3.1.2 Volkanik formlara yakınlık


Obruklar, çoğunlukla karbonatlı kayaç üzerinde ana kaya çökme obrukları şeklinde ya da ana kaya üzerini örten alüvyon örtünün çökmesi şeklinde gerçekleşir (Caramanna vd., 2008). Obruk oluşumu hakkındaki yaygın görüşe rağmen volkanik kökenli kayaçlarda da çok nadir meydana gelen obruk oluşumlarına rastlanmaktadır. Karstik boşlukların üzerindeki ana kaya veya örtü kayaları çökme sürecinden etkilenir. Aşağı sarkma eğilimi daha fazla olan evaporitlerde tabakalar arası karstlaşma daha geniş alanları etkileyerek örtü kayasının çökmesine neden olur. Çözülebilir nitelikteki karbonatlı kayaçlar, bazı alanlarda bazalt, tuf, aglomera vb gibi magmatik kayaçlar tarafından ince bir tabaka şeklinde örtülürler. Bu üst örtü tabakasına kapak kaya, bu alanlarda meydana gelen çöküntülere de kapak kaya çökmesi obrukları denilmektedir (Gutiérrez, 2016). Al Issawiah (Suudi Arabistan) bölgesinde kireçtaşlarının altında

bulunan neojen yaşı bazaltlarda meydana gelen obruklar bu tür oluşumlardır (Şekil 2.5).



Şekil 2.5. Suudi Arabistan'ın Al Issawiah bölgesinde, karstlaşmış kireçtaşının altında kalan Neojen bazaltlarında oluşan kapak kayası çökmesi obruğu (Gutiérrez, 2016).


Arjantin'in Barda Negra platosundaki bazaltlarda meydana genel çökme yapısını araştırarak çökme senaryolarından birisinin obruk oluşumu olabileceğini araştırmışlardır (Michelena vd., 2020). Macaristanda bulunan Güney Bakoni Dağları kireçtaşı ve dolomitten oluşmaktadır ancak zirve kısmında “kab dağı” olarak adlandırılan kısmı ise bazalt lavlar ve lösler ile örtüldüğünü bu alanlarda karbonatlı kayaların ince bir volkanik kayalarla örtülmüş olması halinde kapak kaya dolinleri meydana gelebileceğini belirtmişlerdir (Veress ve Unger, 2015). İtalyada bulunan campania bölgesinde dalma batma zonları olarak ifade edilen jeolojik olayla proklastik yataklar üzerinde Latium bölgesi sınırındaki volkanik alanlarda görülmektedir. Bu oluşumlar ilk olarak krater olduğu varsayılsada daha sonra şiddetli yağışlar sonrası kurak dönemlerde ortaya çıkan ve proklastik çökellerde gerçekleşen obruklar olarak tanımlanmışlardır (Caramanna vd., 2008). Bu tip obruklara havzada özellikle Meke Tuzlası Krater Gölü'nün GB'sında yer alan yılan obrukları örnek verilebilir. Yılan obruğu, volkanik kökenli proklastik malzemeler (tüf, cüruf vb.) gibi örtü malzemesi olarak bulunduğu tipik bir kapak kaya çökme obruğu yapısı görmektedir (Şekil 2.6).



Şekil 2.6. Karapınarda bulunan Meke Tuzlası Krater Gölünün GB'sında yer alan obrukların Google earth görüntüsü.

Canik ve Çörekçioğlu (1985) tarafından yapılan bir çalışmada KKH'da volkanizma ile ilgili bir obruk gelişim modeli üretilmiştir. Bu modelde yeraltı suyunda volkanik aktivite sonucu çözünen CO₂ gazının yeraltı suyuna asidik karakter kazandırmasıyla karstlaşmayı hızlandığını öne sürmektedirler. Bayarı vd. (2009) ise, Obruk platosu altındaki suların jeokimyasal yapısının oldukça korozif olduğunu ve bu durumun hipojenik süreçlerle ilgili güçlü bir kanıt olduğunu belirtmişlerdir. Bu araştırmaya göre obruk platosu altındaki su ve CO₂ gazının volkanik bir kaynak nedeniyle olabileceğini öne sürmüşlerdir (Bayarı vd., 2009).

Bu tez çalışması kapsamında KKH'da yer alan volkanik formlar, Türkiye Topoğrafya Haritası, arazi çalışması ve Google Earth aracılığıyla nokta formatında toplanmış, "Öklid Mesafe Analizi" uygulanarak volkanik formlara yakınlık haritası oluşturulmuştur. Şekil 2.7 incelendiğinde; obrukların volkanik formlara yakın yerlerde yoğunlaştığı gözlemlenmektedir.



Şekil 2.7. Volkanik alanlara yakınlık haritası.

2.3.1.3 Faylara yakınlık


KKH, Neotektonik dönemde meydana gelen levha hareketlerinin etkisiyle D-B ve K-G gidişli yükseltiler arasında kalan, içerisinde Neojen ve Kuvaterner yaşlı sedimanlar ile dolmuş çöküntü alanları olarak oluşmuştur. (Ketin, 1968). Havzada, neotektonik dönemde gelişen blok faylanmalar sebebiyle birbiriyle yatay ve düşey geçişli, akarsu, delta ve göl ortamlarında oluşmuş çok sayıda kırıntılı ve karbonatlı sedimanları barındırır (Koçyiğit, 1984). Anadolu bölgesinin tektonik yapısı levha sınırlarının hareket yönüne göre eğim atımlı ve doğrultu atımlı olmak üzere iki gruba ayırmak mümkündür. Blokların düşey hareketleri normal ve ters olmak üzere eğim atımlı fayları, yatay hareketi ise doğrultu atımlı fayları meydana getirmektedir (Ketin, 1968). KKH'da obruklar genellikle faylara yakın ve yaklaşık K-G uzantılı paralel olarak kümelenmekte olup faylardan önemli derecede etkilenmektedir. Fayların oluşması ile meydana gelen yer değiştirme miktarına bağlı olarak hareket eden blokları arası kil breş kalsit vb. gibi malzemelerle dolarak geçirimsiz birimlerin oluşmasına ya da andezit bazalt gibi geçirimsiz kayaların tektonik hareket etkisiyle geçirimli hale gelmesine neden olabilir. Faylar ve faya yakın alanlarda, yüzeyde meydana gelen

değişimler, yeraltı su seviyesinin dalgalanmasına ve karbonatlı kayaçlarında daha hızlı çözünerek karstlaşmayı hızlandırmaktadır (Göçmez vd., 2022).

Doğu Anadolu sıkışma ve Batı Anadolu genişleme tektonik rejimleri arasında kalan KKH'nda, doğrultu atımlı, normal ve ters faylardan oluşan karmaşık deformasyonlar gözlemlenmektedir (Emre vd., 2018). Tuz Gölü Fay Zonu (TGFZ) ile Eskişehir fayları, bölgeleri Batı ve Orta Anadolu olarak iki tektonik bölgeye ayırır (Barka ve Reilinger, 1997). TGFZ, Şereflikoçhisar ile Bor arasında KB-GD doğrultusunda 200 km boyunca uzanır ve 6 geometrik parçadan oluşur. TGFZ'nun doğu bloğu normal fay mekanizmasıyla uyumlu bir morfolojik yapıdadır. Tuz Gölünü barındıran batı bloğu ise taban bloğu morfolojisinde olup benzer morfolojik yapı tüm KKH'nda gözlenir (Emre vd., 2018). Nasuhpınarı Fayı, seyithacı fayı, Hotamış fayı ve Konya fayı ise KKH'ndaki Holosen aktif eğim atımlı normal faylardandır (Emre vd., 2013). KB-GD gidişli Akşehir fay zonu (AFZ), Beyşehir fayı (BF) ve Emirdağ fayları (EMF) yükseltileri sınırlayan önemli faylardandır. Eldeş Fayı (ELF), Güvenç Fayı (GF), İnsuyu Fayı (İF), Ilgın Fayı (IF), Altınekin Fayı (AF) ve Karaömerler (KF), Divanlar (DF) ve Göçü Fayları (GÖF) konya ovasını sınırlayan havzadaki önemli neotektonik unsurlardır (Coşkun vd., 2021). Havzayı sınırlayan kenar faylar ve dışında çöküntü ve yükselti alanlarında farklı uzunluk ve uzantılarda çok sayıda adlanmamış fay zonları bulunmaktadır (Coşkun vd., 2021).

Fay verileri için MTA Genel Müdürlüğü tarafından üretilen diri faylar ve kuvaterner faylar sayısallaştırılarak CBS ortamına aktarılmıştır. Elde edilen verilere öklid mesafe analizi yöntemi uygulanarak faya yakınlık haritası oluşturulmuştur (Şekil 2.8).

Bu tez kapsamında, Çalışma alanında DSİ Genel Müdürlüğü tarafından rasat kuyularına ait veriler temin edilmiştir. 2018-2022 yılları arasındaki rasat verileri ayrıştırılarak yıllık ortalama yeraltı su seviyesi değişimi tespit edilmiştir. Bu verilere, Ters Mesafe Ağırlıklandırma (Inverse Distance Weighted (IDW)) enterpolasyon yöntemi uygulanarak yeraltı su seviyesi değişim hızı haritası üretilmiştir (Şekil 2.9).




Şekil 2.9. Yeraltı su seviyesi değişimi.

2.3.1.5 Elektriksel iletkenlik

Elektiriksel iletkenlik, yeraltı suyu ve kayaç ilişkisi süresine bağlı olarak değişmektedir. Yeraltı suyu, kayaç ile fazla süre temas ederse iyon içeriği zenginleşerek elektriksel iletkenliği artacaktır. Suyun yeraltında kalış süresi az ve mevsimsel yağışlardan yeterince besleniyor ise Elektriksel iletkenlik değeri düşük olacaktır (Dursun, 2022). Elektriksel iletkenliğin yüksek olması yeraltı suyu deşarj alanların olduğu alanları ve suyun iyon içeriğini yansıtmakta olup Elektriksel iletkenlik değeri yükseldikçe iyon içeriği artacağından suyun kayaçları çözme kabiliyeti azalır (Galve vd., 2009a). Yeraltı suyunun Elektriksel iletkenlik değeri, bize suyun tuzluluğu ve PH değeri hakkında fikir verebilir (Özdemir, 2016). EC ile PH değeri arasında doğrusal bir ilişki vardır (Corwin ve Yemoto, 2020). Elektriksel

iletkenlik arttıkça suyun PH değeri artar, suyun PH değeri ise bize suyun asidik ya da bazik karakterliği olduğu hakkında bir fikir verir. Teorik olarak PH değeri; 1-6.5 arası asidik, 6.5-7 arasında nötr ve 7 den büyük ise bazik özelliğindedir (Ölmez ve Saraç, 2009). Elektriksel iletkenlik değerinin düşük olduğu bölgelerde yeraltı suyunun asidik karakterli olması beklenir. Bu sebeple bu bölgelerde karbonatlı kayaların daha hızlı çözünmektedir.


Bu tez çalışması kapsamında, elektriksel iletkenlik verisi, DSİ Genel Müdürlüğü rasat kuyu verilerinden temin edilmiştir. Bu kapsamda nokta veri formatında elektriksel iletkenlik verisi, Ters Mesafe Ağırlıklandırma (Inverse Distance Weighted (IDW)) enterpolasyon yöntemi uygulanarak elektriksel iletkenlik dağılım haritası üretilmiştir (Şekil 2.10). inceleme alanının elektriksel iletkenlik değeri ise 0 ile 70972 (S/cm) aralığında değişmektedir.



Şekil 2.10. Elektriksel iletkenlik haritası.

2.3.2 Topoğrafik faktörler

Bu tez çalışması kapsamında obruk duyarlılık haritasının üretilmesi amacıyla ALOS PALSAR tarafından üretilen 12.5m x 12.5m çözünürlüğe sahip sayısal yükseklik verisi indirilerek çalışma alanı sınırlarına göre kesilmiş ve projeksiyon, datum ve




Şekil 2.11. Yükseklik haritası.

2.3.2.2 Eğim

Eğim, obruk için önemli bir faktör olması sebebiyle obruk modelleme çalışmalarının birçoğunda kullanılmıştır (Bui vd., 2018; Elmahdy ve Mostafa, 2013; Gutiérrez ve Cooper, 2002; Lumongsod vd., 2022; Özdemir 2016; Pourghasemi vd., 2013; Sarı 2017; Sun vd., 2024). Düz ve eğimi az olan alanlarda yağışın yeraltı suyuna karışması ve sediman birikme oranı daha fazladır (Elmahdy ve Mostafa, 2013). Yüksek eğime sahip dik yamaçlarda akış fazla ancak düşük eğimlerde akış daha yavaş olması sebebiyle suyun yüzeyde kalma ve yeraltına sızma süreside fazladır (Aydın ve İban, 2023). Dolayısıyla eğimi az olan alanlarda obruk oluşumu daha fazla olacağından eğim ile obruk oluşumu arasında bir orantı vardır. KKH’nda eğim değerleri 0° ile 82° arasında değişmektedir.

Eğim faktörü, yükseklik verisinden WGS 84 36.zone projeksiyon ve datumunda 20 metre çözünürlükte türetilmiştir. Buna göre KKH’nda eğim değerleri 0° ile 82° arasında değişmektedir (Şekil 2.12).




Şekil 2.12. Eğim haritası.

2.3.2.3 Bakı

Bakı, obruk duyarlılık haritalarının üretilmesinde kullanılan topoğrafik faktörlerden biri olup birçok çalışmada kullanılmıştır (Arik vd., 2023; Boualla vd., 2016; Galve vd., 2008; Galve vd., 2009b). Bakı, çalışma alanındaki yamaçların ve eğimin yönünü ifade eden bir kavramdır (Pradhan vd., 2014). Jeomorfolojiye bağlı olarak bir alandaki rüzgâr, yağış alma ve güneşlenme süresi gibi parametreler bakı etkisiyle diğer alanlara göre daha fazladır (Akıncı vd., 2010). Bu durumun yeraltı suyu akış yönü ve erozyon hızına dolaylı olarak bir etkisi vardır. Yeraltı suyu akış yönü ve erozyon hızı ise obruk oluşumunda çok etkili faktörlerden biridir. Havzada obruklar, kuzeybatı ve kuzeydoğu yönünde yoğunlaşmış olup yeraltı suyu akış yönüne paralel olarak sıralanmaktadır. Bazı çalışmalarda, obruk oluşumuna bu sınırlı katkı göz önünde bulundurularak çalışmaya dâhil edilmiştir (Galve vd., 2008, 2009; Kim vd., 2019; Orhan vd., 2020b; Özdemir 2015a).

Bakı faktörü, yükseklik verisinden WGS 84 36.zone projeksiyon ve datumunda 20 metre çözünürlükte türetilmiştir (Şekil 2.13).




Şekil 2.13. Bakı haritası.

2.3.2.4 Akarsuya yakınlık

Akarsuya yakınlık, obruk araştırmalarında kullanılan önemli bir topoğrafik parametredir (Karaguzel vd., 2020; Kidanu vd., 2018; Todd ve Ivey-Burden, 2016). Akarsuya yakınlık; bir alandaki yağış ile biriken suyun yüzeyden veya yeraltından nasıl bir akış gösterdiğini ifade etmektedir (Calligaris vd., 2017). Akarsuya yakınlık arttıkça yağmur suyunun belirli bir alanda hızlı bir şekilde uzaklaştığı ve su birikiminin az olacağı anlamına gelir. Bu sebeple akarsuya yakınlık değeri az olan alanlarda obruklaşma oranı daha yüksektir (Özdemir, 2015a).

Akarsuya yakınlık faktörü için; DSİ Genel Müdürlüğünden elde edilen akarsu verisine öklid mesafe analizi uygulanmış ve akarsuya yakınlık haritası oluşturulmuştur (Şekil 2.14).




Şekil 2.14. Akarsuya yakınlık haritası.

2.3.2.5 Topoğrafik nemlilik indeksi (TWI)

TWI, bir bölgedeki topoğrafik özelliklerin (yükseklik, eğim vb.) yerel nem düzeyleri ile ilişkisini analiz ederek suyun birikebileceği alanları ve toprağın suya doygunluğunu ifade eden ve obruk araştırmalarında sıklıkla kullanılan topoğrafik bir faktördür (Nefeslioglu vd., 2021; Yu vd., 2022). Özdemir (2015a), Karapınar ve çevresinde yaptığı bir çalışmada düşük TWI değerine sahip alanlarda obruklaşmanın daha yoğun olduğunu belirterek bu durumu ise kurak dönemlerde yüksek TWI değerine sahip alanlarda toprağın doymuş hale gelerek yüzeysel su akışını hızlandıracağını ve obruklaşmanın düşeceğini ifade etmişlerdir.

TWI için yükseklik verisi kullanılarak eğim yüzeyi oluşturulmuş ve sırasıyla akış yönü ve akış birikimi hesaplanmıştır. Daha sonra akış biriken alanların eğim yüzeylerine oranları hesaplanarak TWI haritası elde edilmiştir (Şekil 2.15).




Şekil 2.15. Topoğrafik nemlilik indeksi haritası.

2.3.2.6 Akarsu aşındırma indeksi (SPI)

Akarsu aşındırma İndeksi (SPI); bir akarsuyun taşıma kapasitesini ve erozyon gücünü belirlemek için kullanılan bir terim olup obruk duyarlılık haritalarında kullanılan önemli topoğrafik faktörlerden biridir (Arik vd., 2023; Wang vd., 2022). SPI, Havza alanı ile eğimin radyan cinsinden değerini ifade eder (Badola vd., 2023). Akarsu aşındırma gücü, suyun akış hızı ve sediman taşıma miktarına bağlı olarak çevrelerini aşındırabilmektedir (Pourghasemi vd., 2013). SPI değerinin düşük olduğu alanlarda suyun akış hızının da düşük olacağından sediman birikimi ve obruklaşma artacaktır. KKH'da negatif değerler akarsunun yatak malzemesi taşıma kapasitesinin düşük olduğunu pozitif değerler ise yüksek olduğunu gösterir.

SPI haritası için, yükseklik verisi kullanılarak eğim yüzeyi oluşturulmuş ve sırasıyla akış yönü ve akış birikimi hesaplanmıştır. Daha sonra akış biriken alanlar ve eğim yüzeylerinin çarpılarak SPI haritası elde edilmiştir Buna göre havzada SPI değerleri -38.8 ile 24.8 arasında değişmekte olup obruklar yaklaşık -2 ile 0 arasında düşük SPI değerlerinde yoğunlaşmaktadır (Şekil 2.16).



Şekil 2.16. Akarsu aşındırma gücü indeksi.


2.3.3 İklimsel faktörler

Havza bazında obruk duyarlılık haritasının üretilmesi için, ortalama su buhar basıncı, ortalama sıcaklık ve ortalama yağış faktörleri seçilmiştir. İklim verileri için WordClim veri seti kullanılmıştır (URL-2). Bu amaçla 30 sn çözünürlüklü ortalama iklim verileri aylık olarak ayrı ayrı raster formatında indirilmiş, her bir raster veri için Arcgis 10.2 yazılımında çalışma alanına göre kesilip tüm raster verilerin toplanarak aritmetik ortalamaları alınarak faktör haritaları elde edilmiştir.

2.3.3.1 Yağış

KKH, Türkiye'nin en kurak ve en az yağış alan bölgesidir (Poyraz ve Nazik, 2016). Havzanın kuzey kesimlerinde karasal iklim hâkim olurken güneyinde ise akdeniz iklimi hâkimdir (Orhan vd., 2020a). Obrukların yoğunlaştığı Karapınar, Eski, Sultanhanı gibi bölgelerde ise çöl iklimi hâkim olup bu bölgede gerçekleşen yağış miktarı Devlet Meteoroloji istasyonu 2023 yılı yıllık ortalama yağış miktarı verilerine göre 27.5 mm dir. Yağış, yeraltı su seviyelerini ve akiferlerin beslenmesini sağlayarak yeraltı suyu deşarj oranını kontrol etmektedir (Taheri vd., 2019). Şiddetli yağışın bölgedeki diğer bir etkisi ise yüzey yarılmaları ve çöküntülerdir (Pradhan vd., 2014). Obruk oluşumlarında genel kanaat yağışın azlığı gibi gözüksede bölgede gerçekleşek


şiddetli bir yağışın obruk oluşumunda daha fazla etkisi olabilir (Arabameri vd., 2020; Yu vd., 2022). KKH için yağış değerleri 27 ile 61 mm arasında değişmektedir (Şekil 2.17).



Şekil 2.17. Yağış haritası.

2.3.3.2 Sıcaklık


Sıcaklık, kayaçların kimyasal ve fiziksel aşınma süreçlerini etkileyen faktörlerden biridir (Kidanu vd., 2018). Obruk oluşumunda ana etken, jeolojik süreçler olsada yağış ve sıcaklığın yeraltı suyu seviyesinin değişiminde tetikleyici bir rolü vardır. (Sarı ve Yalçın, 2023). KKH gibi kurak ve yarı kurak iklime sahip alanlarda yüksek sıcaklık ve düşük yağış, yeraltı suyuna olan talebi artırır (Orhan vd., 2020). Yeraltı suyunun deşarj (yeniden dolma) oranı ortalama sıcaklık ve yağışa bağlı olarak değişmekte olup obruklar üzerinden dolaylı bir etkisi bulunmaktadır (Taheri vd., 2019). Bu kapsamda KKH için sıcaklık değerleri, 0.13 ile 12.51 derece arasında değişmektedir (Şekil 2.18).



Şekil 2.18. Sıcaklık haritası.

2.3.3.3 Ortalama su buhar basıncı

Su buhar basıncı, atmosferdeki su buharının miktarını ifade eden bir terimdir. Yağışların az olması yeraltı su seviyesini, sıcaklık ise yüzey sularının buharlaşmasını etkilemektedir (Sarı ve Yalçın, 2023). Bu kapsamda su buhar basıncı değerleri KKH için 0.29 ile 0.87 Hpa arasında değişmektedir (Şekil 2.19).



Şekil 2.19. Su buhar basıncı.


2.3.4 Çevresel ve antropojenik faktörler

Bu tez kapsamında çevresel ve antropojenik faktör olarak su yüzeylerine mesafe, yola yakınlık, yerleşim yerlerine yakınlık, arazi kullanımı, NDVI ve kuyu yoğunluğu kullanılmıştır.

2.3.4.1 Su yüzeylerine mesafe

Su yüzeylerine yakınlık faktörü, obruk araştırmalarında kullanılan önemli bir çevresel ve antropojenik faktördür (Hyland vd., 2006; Kidanu vd., 2018). Göletler ve akarsular gibi su yüzeylerine yakın yerlerde obruk oluşumları yoğunlaşmaktadır ancak burada su yüzeyleri, doğal olabileceği gibi antropojenik de olabileceğinden su yüzeyleri ile ilişkili doğrudan bir etkisi olmayabilir (Doctor ve Doctor, 2012). Yüzey suları drenaj hatlarına doğru hareket etmesi, taşıdığı kil ve kum silt vb. sedimanların yeraltında oluşan boşluğa dolarak çökmesine neden olabilir (Arik vd., 2023).


Su yüzeylerine yakınlık için, DSİ Genel Müdürlüğün verisi kullanılarak öklid mesafe analizi uygulanmış ve faktör haritası oluşturulmuştur (Şekil 2.20).



Şekil 2.20. Su yüzeylerine mesafe.

2.3.4.2 Yollara yakınlık

Yollara yakınlık faktörü, obruk duyarlılık haritalarının üretilmesinde çoğunlukla kullanılan çevresel ve antropojenik faktörlerden biridir (Bausilio vd., 2022; Kidanu vd., 2018; Sarı vd., 2021). Obrukların bulunduğu kırıntılı ve karbonatlı karstik alanlar harekete ve titreşimlere duyarlıdır. KKH'da obrukların bulunduğu alanlar ise tarım arazilerinde yoğunlaşmakta olup bu bölgedeki obruklar, biçerdöver ve traktör hareketi sonrasında meydana gelmektedir (Sarı, 2017). Karayolu verisi, 1/100.000 ölçekli Çevre Düzeni Planları üzerinden sayısallaştırma yoluyla elde edilmiştir. Elde edilen vektör verilere öklid mesafe analizi yöntemi uygulanarak yollara yakınlık haritası üretilmiştir (Şekil 2.21).




Şekil 2.21. Yola yakınlık.

2.3.4.3 Yerleşim alanlarına yakınlık

Yerleşim alanlarında binalar, yollar, endüstriyel alanlar ve buna bağlı olarak, bölgedeki yoğun nüfus nedeniyle yeraltı su seviyesi düşümü, plansız yapılaşma nedeniyle doğal drenajın bozulmasına ve obruk oluşumunu etkileyebilmesi nedeniyle birçok araştırmacı tarafından dikkate alınmıştır (Sarı vd., 2021; Yılmaz vd., 2013). Yerleşim yerlerine yakınlık faktörü, 1/100.000 ölçekli çevre düzeni planları üzerinden


sayısallaştırma yoluyla elde edilmiştir. Elde edilen vektör verilere öklid mesafe analizi yöntemi uygulanarak yerleşim alanlarına yakınlık haritası üretilmiştir (Şekil 2.22).



Şekil 2.22. Yerleşim alanlarına yakınlık.

2.3.4.4 Arazi kullanımı

Arazi Kullanımı, yeraltı su seviyesi değişimi ve bitki örtüsü değişimi gibi obruk oluşumunu neden olan doğal süreçleri etkileyen önemli bir faktördür (Bianchini vd., 2019, 2022; Taheri vd., 2015). Tarımsal faaliyetler nedeniyle aşırı yeraltı suyu kullanımı, kimyasal gübre kullanımı ve doğal drenajın bozulması vb. etkiler sebebiyle, topraktaki iç erozyonunu artırarak obruklara neden olabilir (Bordbar vd., 2024; Kim vd., 2022). Arazi Kullanımı verisi, ESA'ya ait 2021 yılı verisi raster formatından indirilerek ormanlık alanlar, çalılık alanlar, çayır-mera, tarım alanları, yerleşim alanları, seyrek bitki örtüsü, su yüzeyleri ve sulak alanlar olmak üzere 8 kategoride yeniden sınıflandırılmıştır (Şekil 2.23).



Şekil 2.23. Arazi kullanımı.


2.3.4.5 Normalize edilmiş fark bitki örtüsü indeksi (NDVI)

NDVI, çalışma alanındaki bitki örtüsünün büyümesini ve biyokütlesini tahmin etmek için uydu görüntüleri üzerinden kapladığı alanı ölçerek yapılan bir işlemdir (Qiu vd., 2020; Yılmaz vd., 2013). NDVI değerlerinin 0.1 ve altı değerleri kum, kar yüzeyi gibi çıplak kayalık alanları, 0.2-0.3 arası değerler, çalı ve otlak alanları, 0.6-0.8 arası değerler ılıman ve tropik yağmur ormanlarını gösterir (Weier ve Herring, 2005). NDVI, genellikle bir uydu veya hava aracı tarafından toplanan çok spektral bantlı görüntülerden hesaplanır. Bu görüntüler, kırmızı ve kızılötesi ışık spektrumlarını içerir. Kırmızı (Red) bant, bitki klorofil tarafından yansıtılan ışığı ölçer. Kızılötesi (Near-Infrared) bant, sağlıklı bitki hücrelerinin daha az yansır, normal sağlıklı bir bitki hücrelerini ise büyük bir bölümünü yansır (Qiu vd., 2020). NDVI, kırmızı ve kızılötesi bantların kullanımıyla bir formül kullanılarak hesaplanır. Denklem 2.1’de gösterilmiştir.

$$NDVI = (NIR + Red)/(NIR - Red) \quad (2.1)$$

Burada NIR, kızılötesi banttan alınan değeri, Red ise kırmızı banttan alınan değeri temsil eder.

NDVI haritası için 2023 yılı ağustos ayına ait Landsat uydu görüntüleri kullanılmıştır. KKH için NDVI değerleri; -0.22 ile 0.56 arasında değişmektedir (Şekil 2.24).




Şekil 2.24. NDVI haritası.

2.3.4.6 Kuyu yoğunluğu

Birçok araştırmacı KKH’da obrukların yeraltı su seviyesinin azalmasına bağlı olarak oluştuğu bunun nedeninin ise bölgede uygulanan yanlış tarım uygulamaları sonucunda çok fazla sayıda kuyunun açılması olarak gösterilmektedir (Orhan vd., 2020a; Özdemir, 2015b, 2016; Sarı, 2017; Sarı vd., 2021). KKH’da 100.000’den fazla ruhsatlı ve ruhsatsız kuyu bulunmakla beraber bunun yaklaşık %20’si kayıt altına alınarak ruhsatlandırıldığı tahmin edilmektedir (Nalbantçılar vd., 2009).

Bu tez çalışması kapsamında DSİ genel Müdürlüğü’nden edinilen 23.605 adet kuyu verisine yoğunluk analizi yöntemi uygulanarak kuyu yoğunluğu haritası oluşturulmuştur (Şekil 2.25).



Şekil 2.25. Kuyu yoğunluğu.

2.4 Faktör Seçimi

2.4.1 Çoklu bağıllık (Multicollinearity)

Çalışma alanı koşullarını yansıtan faktörlerinin doğru değerlendirilmesi, obruk duyarlılık haritası üretiminin en önemli adımlarındandır. Duyarlılık haritası aşamasında ilk olarak yerel koşullar göz önüne alınarak kullanılmasına gerek olmayan, modelin aşırı öğrenmesi ve performansını düşürebilecek koşullandırma faktörlerinin veri setinden ayıklanarak çıkarılması gerekmektedir (Aydın ve İban, 2023). Obruk tahmininde, koşullandırma faktörlerini çoklu bağıllık (multicollinearity) testi ile değerlendirerek faktörlerin eğitim veri seti ile nasıl bir ilişki içerisinde olduğunu bakılır. Eğer ilişkili faktörler veri setinden ayıklanmazsa yüksek korelasyon değeri verir ve modelin tahmin performansı düşer (İban ve Bilgilioglu, 2023).

Çoklu bağlanım problemine sahip faktörler, Tolerans (TOL) ve Varyans Enflasyon Faktörü (VIF) gibi istatistik temelli ölçütler kullanılarak veri setinden ayıklanabilir. VIF değeri 10'dan büyük ve TOL değeri ise 0.1 den küçük olması, çoklu bağlanım varlığını gösterir. Bu değerlere sahip faktörlerden veri setinden her seferinde biri olmak üzere teker teker çıkartılır ve VIF ve TOL ölçütleri tekrar hesaplanır (Arabameri

vd., 2020; Bausilio vd., 2022; Kidanu vd., 2018; Sun vd., 2023; Tien vd., 2016; Yu vd., 2022). Böylece çoklu bağlanım problemi veri setinden ayıklanmış olur.

Çoklu bağlanım problemlerini çözmek ve çoklu bağlanım test sonuçlarını desteklemek amacıyla kullanılan bir çok yöntem mevcut olup bu tez çalışması kapsamında pearson korelasyon ilişkisi matrisi yöntemi kullanılmıştır. Bu yöntemde, veri setinde belirli bir eşik değer (örneğin pozitif korelasyon $> 0,75$ ile negatif korelasyon $< -0,75$ gibi) belirlenir. Koşullandırma faktörlerindeki korelasyon kat sayısı, belirlenen eşik değerden sırasıyla düşük ve büyük olduğu durumlar negatif korelasyon ve pozitif korelasyon olarak kabul edilir. Bu durumlarda da faktörlere ait korelasyon katsayıları her seferinde ilişkili bir faktör çıkartılarak tekrar hesaplanır ve korelasyon analizinden ilişkili faktör çıkartılarak veri seti ayıklanmış olur (Wang vd., 2022).

2.5 Obruk Duyarlılık Modelleri

Obrukların oluşumuna elverişli alanların tespit edilerek duyarlı alanların mekânsal olarak modellenmesi son derece önemlidir. Ancak obruk oluşumuna etki eden birçok faktörün etkisi olması sebebiyle mekânsal ve zamansal olarak modelleme yapmak son derece güçtür (Perrin vd., 2015; Wang vd., 2022; Xie vd., 2022). Geçmişte obruk olan lokasyonların hangi koşullar altında olduğunu analiz edilmesi ve potansiyel obruk oluşumu olabilecek alanların belirlenmesi temelde obruk duyarlılık alanlarının ana fikrini yansıtmaktadır (Gutiérrez, 2016). Tahmin yapabilmek için farklı türde modelleme araçlarına ihtiyaç duymaktadır. Obrukların, benzer jeolojik, hidrojeolojik, jeomorfolojik, çevresel ve iklimsel koşullar altında tekrar etme olasılığı yüksektir. Bu faktörleri analiz ederek obrukların mekânsal olarak hangi koşullar altında oluşabileceği sorusuna cevap arayan birçok yöntem geliştirilmiştir (Bilgilioğlu ve Bilgilioğlu, 2023).

Literatürde, Obruk duyarlılık modelleri üretmek amacıyla nicel ve yarı nicel yöntemler olmak üzere ikiye ayrılmaktadır. Nicel yöntemler, araştırılan olayı çalışma alanındaki sayısal veriler toplanması ve analiz edilmesiyle yoluyla açıklamaktadır. Yarı nicel yöntemler ise olayı, hem sayısal veriler toplayarak hemde gözleme dayalı olarak analiz ederek açıklayan yöntemlerdir (Bilgilioğlu ve Bilgilioğlu, 2023). Literatürde sıklıkla kullanılan nicel yöntemleri deterministik, istatistik ve makine öğrenmesi yöntemleri olarak 3'e ayırmak mümkündür. Bu yöntemler, obruk duyarlılık modellerinde

kullanılan faktörlerin seçiminde uzman görüşüne kısmen daha az ihtiyaç duyan ve otomatik çözümler üreten yöntemlerdir (Arik vd., 2023).

2.5.1 Yarı nicel yöntemler

Bu modeller, koşullandırma faktörlerinin obruk oluşumuna katkısını uzman görüşüne ya da deneyime bağlı olarak oluşturulan duyarlılık modelleridir (Gutiérrez, 2016). Modellerde, matematiksel denklemlerin yanısıra bölgede çalışması olan uzmanların görüşü, deneyimlere veya basit kurallara kullanılarak analiz yapılır (Gao ve Alexander, 2008). Bazı araştırmacılarda, koşullandırma faktörlerine bir puanlama veya ağırlıklandırma sistemi kullanmışlardır. Uzman görüşü ve deneyimin, bu yaklaşımda duyarlı bölgelerin sınırlarını ve dağılımını doğrulamak için önemli bir bileşene sahip olması sebebiyle nesnel bir temelden yoksundur. Obruk duyarlılık haritalarının üretilmesinde en çok kullanılan yarı nicel yöntem ise Analitik Hiyerarşi Prosesi (AHP) yöntemidir (Orhan vd., 2020a; Rosdi vd., 2019; Sarı vd., 2021; Wei vd., 2021; Wu vd., 2018; Xie vd., 2022).

2.5.2 Nicel yöntemler

2.5.2.1 Deterministik yöntemler

Deterministik yöntemler, obruk oluşum süreçlerini analiz ederken jeolojik, hidrojeolojik ve jeoteknik gibi elde edilmesi pahalı ve zaman alan büyük miktarda veriye ihtiyaç duyan veri güdümlü nicel yöntemlerdir (Gutiérrez, 2016). Bu modeller obruk sürecinin karmaşık yapısını açıklamakta oldukça etkilidir. Model oluştururken bir takım matematiksel denklemlerle yardımıyla obruk ile ilgili kesin sonuçlar almayı hedeflerler. Detaylı jeolojik, jeoteknik ve hidrojeolojik veriye ihtiyaç duyması sebebiyle oldukça zaman alıcı bir süreç içerirler. (Arik vd., 2023). Model ile koşullandırma faktörü arasındaki ilişki kullanılan matematiksel denlem yardımıyla analiz edilerek faktör ağırlıkları belirlenir ve model oluşturulur (Sarı ve Yalçın, 2023).

2.5.2.2 İstatistiksel yöntemler

Bu yöntemler, mekânsal konumları bilinen obrukların bir takım kontrol eden faktörlerin ilişkilerini istatistiksel ilişkilerini inceleyen ve bu faktörlerin bazı durumlarda karşılık ilişkilerini analiz ederek duyarlılık modellerinin oluşmasına

yardımcı olurlar (Gutiérrez, 2016). İstatistik yöntemler, temelde iki değişkenli (İDİA) ve çok değişkenli istatistiksel analiz (ÇDİA) olarak ikiye ayrılır.

İDİA, hedef değişkenin mekânsal konumları ile değişkenin oluşma koşullarını ve dağılımlarını inceleyerek belirli değişkenleri analiz eden yöntemlerdir (Gutiérrez, 2016). Obruk araştırmalarında; obruk yoğunluğu, (Doctor ve Doctor, 2012; Lindsey vd., 2010; Whitman vd., 1999), kanıt ağırlığı (Özdemir, 2015a; Perrin vd., 2015), frekans oranı (Bianchini vd., 2019; Kim vd., 2022) ve korelasyon analizi (Lumongsod vd., 2022; Sarı vd., 2021) gibi yöntemler kullanılmaktadır.

ÇDİA, yöntemi, ikiden fazla değişkenin yer aldığı veri setinde değişkenler arasındaki ilişkileri veya değişkenlerin birlikte nasıl değiştiğini analiz ederek inceleyen yöntemlerdir (Admassu ve Woodruff, 2021). İDİA ve ÇDİA arasındaki temel fark her bir koşullandırma faktörünün envanter haritası ile inceleme yöntemleridir (Süzen ve Doyuran, 2004). İDİA’de elde edilen ağırlık değerleri, her bir koşullandırma faktörünün sınıfıyla ilişkisini analiz ederek tahmin edilirken, ÇDİA’ de koşullandırma faktörü tek tek değil grup olarak ağırlıklandırılmaktadır. ÇDİA, koşullandırma faktörünün obruk oluşumu üzerindeki göreceli etkisini değerlendirmektedir (Tehrany vd., 2013). ÇDİA yönteminde olay sayısının fazla olduğu durumlarda yüksek tahmin kabiliyetine sahiptir ancak yöntemin temel zayıflığı her bir faktörün obruk oluşumuna etkisine ilişkin analizin yokluğudur (Pradhan vd., 2014).

2.5.2.3 Makine öğrenmesi yöntemleri

Yapay zekânın son yıllardaki hızlı ve çok yönlü gelişimi göz önüne alındığında net bir tanım yapmak oldukça zordur. Kısaca bir bilgisayar ya da bilgisayar yardımıyla bir robotun insan zekâsına özgü davranışları yerine getirme kabiliyeti olarak tanımlanabilir (Nilsson, 2014). Yapay zekâ, doğal dil işleme, görüntü işleme, konuşma tanıma, anlama, planlama gibi insana özgü yetenekleri taklit ederek bu becerileri kazanır (Kowalsky, 2011). İlk olarak matematikçi Turing (1950) bir felsefe dergisinde ele aldığı makinelerin düşünmesinin mümkün olup olmayacağı hakkındaki yazısı ile hayatımıza girmiştir.

Makine öğrenmesi ise yapay zekânın bir alt dalı olup bilgisayarların algoritmalar yardımıyla veri setleri üzerinden öğrenimi olarak tanımlanabilir (Alpaydın, 2021).

Heyelan (Ha vd., 2024; Sun vd., 2023), ıg (İban ve Bilgilioglu, 2023), kaya düşmesi (Fanos vd., 2018, 2020), tařkın (Aydin ve İban, 2023; Mohamed ve Mabrouk, 2022) ve obruk gibi afet arařtırmalarında son yıllarda oldukça sık kullanılmaktadır. MÖ yaklaşımında temelde bir görevi gerçekleřtirmek için verileri eğitim ve test verileri olarak ayırmak gerekmektedir. MÖ modeli eğitim verisi üzerinden istatistiki analizlerle eğitilerek buradaki tecrübelerinden yola çıkarak test veri seti üzerinden performansını deęerlendirir (Kim vd., 2018).

MÖ yaklaşımı ile afet duyarlılık haritası oluřturmak için çeřitli sınıflandırma algoritmaları kullanılmaktadır (Çizelge 2.4). Veriler, sınıflandırma algoritmaları ile analiz edilerek kategorize edilir ve sınıflandırılır. Daha sonra algoritma, veriyi analiz ederek öğrendięi bilgileri kullanarak faktörlerin önem oranları belirler ve modeli oluřturulur. Literatürde, lojistik regresyon, karar ağaçları, yapay sinir ağları, destek vektör makineleri gibi klasik MÖ algoritmalarının yanı sıra Rastgele Orman, XGBoost LightGBM, AdaBoost ve CatBoost gibi topluluk öğrenme MÖ algoritmalarıda afet duyarlılık modellerinde kullanılmıştır (Amin vd., 2023; Ayday ve Alan, 2020; Bausilio vd., 2022; Gao ve Alexander, 2008; Nefeslioęlu vd., 2021; Wang vd., 2022)

Çizelge 2.4. Literatür özeti ve kullanılan obruk duyarlılık modelleri.

No	Kaynak	Makine Öğrenme Modelleri							
		M1	M2	M3	M4	M5	M6	M7	M8
1	Amin vd., 2023		X	X					X
2	Arık vd., 2023		X		X	X	X	X	
3	Ayday ve Alan, 2020								
4	Bausilio vd., 2022				X				X
5	Bianchini vd., 2019								
6	Bianchini vd., 2022								X
7	Boualla vd., 2016								
8	Bruno vd., 2008								X
9	Kim vd., 2018								X
10	Nefeslioęlu vd., 2021			X					
11	Taheri vd., 2019	X							
12	Wang vd., 2022				X				
13	Wang vd., 2022		X						
14	Wei vd., 2021								X
15	Wu vd., 2018								
16	Yılmaz vd., 2013			X					

M1=Neavi Bayes, M2= Destek Vektör Makineleri (DVM) M3=Yapay Sinir Ağları (YSA), M4=Rastgele Orman, M5=XGBoost, M6=LightGBM, M7=AdaBoost, M8= Karar Ağaçları.

Uyumlandırılmış gradyan artırma (AdaBoost) algoritması;

AdaBoost, Robert Schapire ve Yoav Freund tarafından 1995 yılında geliştirilen topluluk öğrenme algoritmasıdır. Bu algoritmanın temel prensibi, zayıf sınıflandırıcıları verilerin değiştirilen versiyonları ile uyumlandırmaya çalışmaktır. Zayıf sınıflandırıcılar, rastsal tahmin performansından çok az daha iyi performans gösteren modellerdir. İlk olarak her eğitim dizisine eşit ağırlık verir ve ağırlıklarını artırarak zayıf sınıflandırıcıları eğitir. Her bir eğitim dizisi iki değere sahip mantıksal bir boolean dizisine karşılık gelmektedir. Bu çalışmada boolean dizisi obruk ve obruk olmayan dizilerdir. Daha sonra her eğitim turunda daha önceki turdaki yanlış sınıflandırılan örneklerle yeniden ağırlık atar ve belirli bir eşik değerde diziyi sonlandırır. Bu işlemde iyi tahmin edilen sınıflandırıcılar büyük, yanlış tahimler ise değer kaybederek düşük ağırlık kazanır (URL-3). Afet tehlike ve duyarlılık çalışmalarında birçok araştırmacı tarafından kullanılmıştır (İban ve Bilgilioglu, 2023; Youssef ve Pourghasemi, 2021).

Kategorik artırma (CatBoost) algoritması;

2017 yılında Yandex tarafından geliştirilmeye başlayan Catboost, özellikle kategorik verileri ele alan Gradyan artırma algoritmasının bir uzantısı olup kategorik verilerle çalışan modellerin performansını artırmak amaçlanmaktadır (Dorogush vd., 2018).

Bu algoritma zayıf modelin katkısını belirlemek amacıyla Denklem 2.2'yi kullanır

$$\Omega(h_m) = \varepsilon p + \frac{1}{2} \lambda \|\delta\|^2 \quad (2.2)$$

Denklem 2.2'de $\Omega(h_m)$, zayıf modelin karmaşıklığını kontrol etmekten sorumlu olan bir düzenleme terimi olarak kullanılır. ε , bir ceza göstergesi; p , yaprak düğüm sayısı; λ , düzenleme göstergesi ve δ ise ağırlık katsayısı olarak işlev görür (Ha vd., 2024).

Rastgele orman (RF) algoritması;

Birçok karar ağacının birleştirilmesiyle oluşturulan bir kolektif öğrenme modelidir (Breiman, 2001). Bu yöntem, büyük veri setleri üzerinde çalışabilme yeteneği ve aşırı uyuma karşı direnci ile bilinir. Çevresel duyarlılık analizi için, geniş ve karmaşık veri setlerindeki örüntüleri belirlemede etkili bir seçenek olması nedeniyle birçok

araştırmacı tarafından tercih edilmektedir (Bausilio vd., 2022; Galve vd., 2008; İban ve Bilgilioglu, 2023; Kim vd., 2018; Prathapchandran ve Janani, 2021).

Rastgele orman algoritmasında, eğitim seti rassal şekilde alt gruplara ayrılır. Algoritma ile her alt grubu eğiterek ayrı ayrı birbirinden farklı modeller oluşturulması sağlanır. Daha sonra her bir model için tahmin sonuçları birlikte değerlendirilerek hata performanslarının aritmetik ortalaması alınır. RF algoritmasının matematiksel modeli Denklem 2.3'te verilmiştir:

$$\hat{Y} = \frac{1}{N} \sum_{n=1}^N T_n(X) \quad (2.3)$$

Yukarıdaki denklemde $\hat{Y}$ toplam tahmin $T_n(X)$ n'inci ağacın X özellik vektörü ile yaptığı tahmin olarak ifade edilir.

Aşırı gradyan artırma (XGBoost);

Washington üniversitesinden Chen ve Guestrin (2016) tarafından geliştirilen XGBoost, ilk önce tahmini yaparak işe başlar ve bu tahminden sonra yapılacak olan tahminlere göre uzaksayarak ya da yakınsayarak en uygun sonuca ulaşmaya çalışır. Yapılan tahminde modelin ne kadar başarılı olduğunu hata tahminleri incelenir. Daha sonra yapılan tahmindeki hatayı bulmak için gözlemlenen değer ile tahmin edilen değere arasındaki farkın çıkarılmasıyla hesaplanır. Bu aşamadan sonra ise hataları tahmin eden bir dizi karar ağacı modeli oluşturularak hataları öğrenip en iyi sonuca ulaşmak hedeflenir (URL-4). XGBoost Denklem 2.4'te verilen matematiksel bağıntıları kullanmaktadır:

$$L(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (2.4)$$

Buna göre; $L(\phi)$ sınıflandırma modelinin kayıp fonksiyonunu $l(\hat{y}_i, y_i)$ tahmin edilen sınıf değeri ile gerçek sınıf arasındaki farkı $\Omega(f_k)$ modelin aşırı uydurmaya karşı her bir ağacın karmaşıklığını kontrol eden terimi ifade etmektedir (İban ve Bilgilioglu, 2023).

Hafif gardyan artırma (LightGBM);

Microsoft mühendisleri tarafından geliştirilen LightGBM algoritması, modelin performansı ve eğitim süresini kısaltmaya odaklanmış bir GBM algoritmasıdır. XGBoost, ağaç derinliği seviyesine göre büyüme hedeflenirken LightGBM yaprak bazlı büyüme stratejisi kullanır (Ke vd., 2017). XGBoost algoritmasına göre daha kısa sürede modeli eğitmekte olup düşük bellek kullanımıyla öne çıkar (Chai vd., 2024). Bu sebeple LightGBM algoritmasını ışık adı verilir (İban ve Bilgilioğlu, 2023). Bu algoritmanın temel fikri, eğitim veri setini dolaşarak her bir ayrık değerin birikmiş istatistiklerini çıkartarak özellik seçiminde daha az bellek kullanımı ve daha düşük veri bölümlleme karmaşıklığı yaratmak amaçlanmaktadır (Sun vd., 2023). LightGBM'in temel denklemi Denklem 2.5'te şu şekilde verilmiştir.

$$H_T(X) = \sum_{i=1}^T H_t(X), H_t \in \Theta \quad (2.5)$$

Burada $H_T(X)$, T adet ağacın X özellik vektörüne göre yapılan i'inci ağacın tahmini ve Θ ise ağaçların oluşturduğu topluluğu ifade etmektedir (Ke vd., 2017).

2.5.3 Model performansı

Bir sınıflandırma problemine en uygun algoritma ve bu algoritma ile oluşturulabilecek en iyi modelin hangisi olduğunu belirlemek için performans ölçümü ve çapraz doğrulama başlıca adımlardandır (Wang vd., 2022). Performans ölçümü; oluşturulan modelin tahmin hatası ve başarısının ölçülerek veri setine en uygun ve en iyi modelin bulunmasıdır.

Model performansını ölçmeden önce veri setiyle hesaplanması gereken bazı ölçütler vardır. Bunlar, doğru pozitifler (TP), doğru negatifler (TN), yanlış pozitif (FP) ve yanlış negatifler (FN) gibi kavramlardır. Örneğin veri setimizde sınıflayıcı algoritma tarafından obruk olarak etiketlenen ve gerçek veri setinde de obruk olan değerlere TP, Veri setinde gerçek değeri ve sınıflandırıcı algoritma tarafından obruk olmayan değerlere ise TN adı verilir. Algoritma tarafından obruk olamayan olarak etiketlenen ancak gerçekte obruk olan değerlere FP gerçekte obruk olmayan ama algoritma tarafından obruk olarak etiketlenen değerlere ise FN adı verilir. Performans ölçüm

metrikleri sınıflayıcı algoritmaların performanslarını belirleyebilmek için bu ölçütlerin hesaplanması gerekmektedir (İban ve Bilgilioglu, 2023).

MÖ algoritmalarında problemlerin türüne bağlı olarak performans ölçüm metrikleri bulunmaktadır. Obruk duyarlılık haritası bir sınıflandırma problemi olması nedeniyle sınıflandırma için kullanılan performans metrikleri kullanılmaktadır. MÖ modellerinin performansını ölçmek için sınıflandırma problemlerinde doğruluk, kesinlik, hassaslık, geri çağırma, özgüllük, F1 skoru gibi çeşitli metrikler bulunmaktadır (Çizelge 2.5). Bu metriklerin yanı sıra Alıcı İşletim Karakteristiği (ROC) eğrisi ve ROC eğrisi altındaki alan gibi performans ölçütleri bulunmaktadır (Prathapchandran ve Janani, 2021; Taheri vd., 2021). ROC afet duyarlılık haritalarında sıklıkla kullanılan bir metriktir (Bianchini vd., 2019; Kim vd., 2019). ROC eğrisi için Y ekseninde gerçek pozitifler ve X ekseninde yanlış pozitifler olarak üzere bir grafik çizilir. Daha sonra grafik üzerinden doğruluk hesaplanır. ROC eğrisi altındaki alan (AUC) ise sınıflandırma modelinin coğrafi dağılımını tahmin etme yeteneği olarak ifade edilir (Hong vd., 2017). AUC değeri 0.5 ve aşağısı kötü tahmin, 0.6-0.7 değerleri ortalama - kabul edilebilir tahmin ve 0.9 ve üzeri ise mükemmel tahmin yeteneği derecesi olduğunu gösterir (İban ve Bilgilioglu, 2023; Taheri vd., 2019).

Bu tez çalışması kapsamında model performans değerlendirmeleri için Python tabanlı scikit-learn kütüphanesi kullanılmıştır (Pedregosa vd., 2011). LightGBM için Microsoft lightgbm (Ke vd., 2017) ve XGBoost içinde XGBoost kütüphanesi (Chen ve Guestrin, 2016) kullanılmıştır.


Çizelge 2.5. Sınıflandırma problemlerinde kullanılan metrikler; hassaslık, geri çağırma, doğruluk, özgüllük, kesinlik, F1-skoru ve AUC.

Metrikler	Formüller	Açıklama
Hassaslık	$\frac{tp}{tp + fp}$	Obruk tahmin yeteneği
Geri çağırma	$\frac{tp}{tp + fn}$	Girdi obruk envanteri ile pozitif olarak tahmin edilen obrukların örneklerin oranı
Doğruluk	$\frac{tp + tn}{tp + fn + fp + tn}$	Sınıflandırma modelinin genel doğruluğu
Özgüllük	$\frac{tn}{fp + tn}$	Obruk olmayan değerleri bulma
Kesinlik	$\frac{tp}{tp + fp}$	Algoritma tarafından tahmin edilen obruk ile obruk envanteri arasındaki ilişki
F1 Skoru	$\frac{2 * \text{hassaslık} * \text{geri çağırma}}{\text{hassaslık} + \text{geri çağırma}}$	Gerçek obruk değerleri ve tahmin edilen obruk değerlerini inceler
AUC	$\frac{1}{2} \left(\frac{tp}{tp + fn} + \frac{tn}{tn + fp} \right)$	Sınıflandırma algoritmasının yanlış tahminden kaçma yeteneği

2.5.4 Hiperparametre optimizasyonu

MÖ algoritmalarında, algoritmanın yapısından kaynaklı belirli aralıklar arasında değişen sabit olmayan bir takım değerler bulunmaktadır. Bu değerlerin ayarlanması ile algoritmanın modelin genel yapısını ve performansını etkilemektedir. Bir tahmin fonksiyonunun hiperparametrelerini öğrenerek aynı veri seti üzerinde test etmesi yanlış bir uygulamadır. Biraz önce öğrendiği veri setini tekrarlayarak oluşturulan model yüksek bir puanına sahip olur ancak genelleme yeteneği ve tahmin performansı düşük olur. Bu duruma ise aşırı uyum (overfitting) problemi olarak adlandırılır (Malalha vd., 2024). Veri setimizde aşırı uyum problemini tespit etmek için verilerin bir kısmını test ve eğitim seti olarak ayırmak ve çapraz doğrulama teknikleri ile model performansının değerlendirilmesi gerekir (URL-5).

MÖ algoritmalarında model eğitilirken hiperparametreler seçilmezse algoritma varsayılan ayarları kullanarak modeli eğitir ve modelin elde edebileceği maksimum performansı elde edememiş olur. Bu nedenle algoritmaya ait hiperparametre uyumlandırması çok önemlidir (Abbas vd., 2024). Ancak temelde MÖ algoritmalarına ait çok sayıda hiperparametre ve bu hiperparametrelere ait onlarca değer aralıkları bulunmaktadır. Tüm değer aralıklarını teker teker denemek ve en uygun hiperparametre aralığını belirlemek ise çok zor olması nedeniyle GridSearchCV ve RandomizedSearchCV olarak iki yöntem bulunmaktadır (Bergstra ve Bengio, 2012). Bu yöntemlerden en sık kullanılanları ise GridSearchCV yöntemidir (Şekil 2.26). GridSearchCV yöntemi, algoritmaların kullanıcı tarafından belirlenen hiperparametre kombinasyon listesi üzerinden veri seti üzerinden permütasyon yöntemiyle teker teker deneyerek en iyi hiperparametre değerini belirler ve MÖ modelleri için en iyi performansa sahip hiperparametre değer aralığı belirlenmiş olur (Pedregosa vd., 2011).



Şekil 2.26. GridSearchCV yöntemi, çapraz doğrulama yöntemi iş akış şeması.

RandomizedSearchCV yönteminde GridSearchCV de uygulanan tüm hiperparametre değerleri denenmez, bunun yerine sabit sayıda parametre örneklenerek çapraz doğrulama yoluyla belirli bir yinleme aralığı (örneğin $n_iter=10$) girerek en uygun değeri bulur (URL-6).

Bu tez çalışması kapsamında hiperparametre aralıklarını belirlemek için GridSearchCV yöntemi tercih edilmiştir.

2.6 Açıklanabilir Yapay Zekâ

MÖ modellerinin açıklanabilirliği kullanılan algoritmanın yapısı ve veri seti ile ilişkili olarak farklılıklar gösterebilir. Modelde kullanılan koşullandırma faktörünün algoritma açısından öneminin değerlendirilmesi gerçek dünyadaki gerçekleşen kabul görmüş görüşlerle ne derecede örtüştüğü hakkında fikir edinmemizi sağlar.

MÖ modellerini açıklamak için çeşitli yöntemler bulunmaktadır. Algoritmanın yapısına göre modelin açıklanabilirliği bazı modellerde kolay olurken bazı modellerde daha karmaşık olarak açıklanabilmektedir. MÖ modellerinde, modelin tahmin yeteneğini değerlendirmek ve modeli açıklamak amacıyla Information Gain (Bilgi kazancı) ve Feature Importance (Öznitelik önemi) gibi yöntemlerin yanı sıra Sahpley değerleri gibi yöntemlerde kullanılmıştır (Aydın ve İban, 2023; İban ve Bilgilioğlu, 2023; Sun vd., 2024; Zhang vd., 2023). Information Gain (Bilgi kazancı), genel olarak

karar ağacı temelli sınıflandırma algoritmalarında kullanılmaktadır (Tien vd., 2016). Bu yöntemde veri setindeki öznitelikleri kullanarak belirli bir dizi karar kuralını oluşturularak her faktörün kendinden önceki durumla analiz edilerek bilgi kazancı en yüksek olan özelliğin seçilmesini ve bir karar noktası oluşturmasını sağlar. Bilgi kazancı hesaplanırken, verileri sınıflandırmanın nasıl bir kazanç sağladığına odaklanarak verilerin bölümlenmesinde daha homojen alt sınıflar oluşturmasını sağlar. Feature Importance (Öznitelik önemi), koşullandırma faktörlerinin modelin tahmin yeteneği üzerindeki etkisini ölçen bir kavramdır. Karar ağacı temelli sınıflandırma algoritmalarında, her bölme noktasında seçilen bir özelliğe göre veriler bölümlenir. Öznitelik önemi, koşullandırma faktörlerinin bu bölünmelerin nasıl yapıldığını ve tahminlere ne derece katkı verdiğini hesaplamak için kullanılan yöntemlerdir.

Global yöntemler modelin genel eğilimini anlamak için kullanışlı olmasına rağmen daha karmaşık veri setlerini açıklamak için yetersiz kalabilmektedir (Arık vd., 2023). Bu aşamada devreye lokal yöntemler girmektedir. Bu yöntemler karmaşık modellerin tahminlerini açıklamak için her bir koşullandırma faktörünü analiz ederek modelin tahmin yeteneğine ne derece etkili olduğunu anlamak için kullanılır. Bu tez çalışmasında kullanılan SHAP (SHapley Additive exPlanations) yaklaşımı ise MÖ algoritmalarını açıklamak için kullanılan lokal yöntemlerden biridir. SHAP yaklaşımı Shapley değerlerini temel alan bir oyun teorisinden üretilmiştir (İban ve Bilgilioglu, 2023). Shapley değerlerini hesaplamak için Python tabanlı SHAP Kütüphanesi kullanılmaktadır. Bu kütüphane karar ağaçları, derin öğrenme modelleri, gradyan artırma modelleri, destek vektör makineleri gibi birçok sınıflandırma modeli üzerinde analizler yapabilmemize olanak tanımaktadır. Bu kütüphane scikit-learn, LightGBM, XGBoost ve diğer MÖ kütüphaneleri ile bütünleşik çalışarak model tahminlerini açıklamak ve anlamak için kullanılır. SHAP değerleri bize afet duyarlılık haritalarında hangi faktörün duyarlılığa katkısının fazla olduğu hakkında fikir verir (Sun vd., 2024). Bu yaklaşımda her bir koşullandırma faktörünün modelin tahmin yeteneği üzerindeki etkisini belirtmek için kullanılır (Sun vd., 2024). Model eğitimi sırasında her bir faktör için bir değer üretir SHAP değeri ise bu değer tahmin yeteneğine etkisini hesaplar (Zhang vd., 2023). SHAP değeri Denklem 2.6'daki formülle hesaplanır.

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (M - |S| - 1)!}{M!} [f(S \cup \{i\}) - f(S)] \quad (2.6)$$

Denklem 2.6’da $\emptyset_i$ i’inci özelliğin katkısını, M , tüm özelliklerin kümesini S , tahmin özelliklerin alt kümesini temsil eder. Formülde $\int (S \cup \{i\})$ ve $\int (S)$ kavramları ise sırasıyla i’inci özellik ile i’inci özellik olmadan model sonuçlarını ifade eder.



3. ARAŞTIRMA BULGULARI

3.1 Veri Toplama ve Hazırlama

Çizelge 2.3'teki literatür özeti ve kullanılan parametreler gözetilerek; yükseklik, bakı, ortalama sıcaklık, ortalama yağış, volkanik formlara yakınlık, litoloji, su yüzeylerine yakınlık, yerleşime yakınlık, ortalama su buhar basıncı, arazi kullanımı, yola yakınlık, eğim, kuyu yoğunluğu, faya yakınlık, akarsuya yakınlık, yeraltı su seviyesi hızı değişimi, NDVI, TWI, SPI ve elektriksel iletkenlik olmak üzere toplamda 20 adet koşullandırma faktörü belirlenmiştir. Bu faktörler; topoğrafik, iklimsel, jeolojik ve çevresel-antropojenik olmak üzere 4 kategori altında toplanmıştır (Çizelge 3.1).

Çizelge 3.1. Obruk duyarlılık haritası için kullanılan koşullandırma faktörleri.

Faktör Grupları	Faktörler	Veri Kaynağı	Açıklama
Jeolojik	Litoloji	MTA Genel Müdürlüğü, AFAD	Vektörel olarak elde edilen verilerden üretilmiştir.
	Faylara Yakınlık	Yerbilimleri mta web sitesi üzerinden sayısallaştırma ile	Yerbilimleri mta web sitesi üzerinden sayısallaştırma ile üretilmiştir.
	Volkanik formlara Yakınlık	Türkiye Topoğrafya Haritası üzerinden sayısallaştırma ile	Sayısallaştırma ile elde edilen verilerden üretilmiştir.
	Yeraltı Su seviyesi değişim hızı	DSİ Genel Müdürlüğü	DSİ tarafından Mevsimlik ve Aylık olarak rasat yapılan 288 adet kuyudan elde edilen 2018-2022 yılları arasındaki verilerler üretilmiştir
	Elektriksel İletkenlik	DSİ Genel Müdürlüğü	Vektörel olarak elde edilen verilerden üretilmiştir.
Topoğrafik	Yükseklik	Alaska Uydu Tesisi Verisi	Vektörel olarak elde edilen verilerden üretilmiştir.
	Eğim	Yükselik verisinden	
	Bakı	Yükselik verisinden	
	Akarsuya yakınlık	DSİ Genel Müdürlüğü	
	SPI	Yükselik verisinden	
	TWI	Yükselik verisinden	
İklim	Ortalama Sıcaklık	WordClim internet sitesi	30 sn'lik geçmiş iklim verilerinden üretilmiştir
	Ortalama Yağış		
	Ortalama Su Buhar Basıncı		
Çevresel Antropojenik	Arazi Kullanımı	ESA Land Cover 2021	Avrupa Uzay Ajansı tarafından belirlenen 2021 yılı Arazi Örtüsü/Kullanımı raster verisi ve 1/100.000 ölçekli Çevre düzeni planı üzerinden üretilmiştir..
	Yerleşim Yerlerine Yakınlık	Çevre Düzeni Planı	
	Su Yüzeylerine Yakınlık	Çevre Düzeni Planı	
	Yollara Yakınlık	Çevre Düzeni Planı	Vektörel olarak elde edilen verilerden üretilmiştir.
	NDVI	Landsat uydu görüntüsü	2023 yılı 8. Aya Landsat uydu görüntüsünden üretilmiştir.
	Kuyu Yoğunluğu	DSİ Genel Müdürlüğü	Ruhsatlı olan 23.605 adet kuyu verisi ile üretilmiştir.

Afet duyarlılık haritalarında kullanılan veri modeli, Raster (Hücresel) veri modelidir. Bu kapsamda tüm veriler, raster (Hücresel) veri formatına dönüştürülmüştür. Literatürde kullanılacak piksel boyutu ile kesin bir bilgi bulunmamakla birlikte genel olarak çalışmalarda 10 ile 30 m arasında değişen piksel boyutu kullanımları mevcuttur. AFAD tarafından son yıllarda üretilen heyelan, çığ ve kaya düşmesi gibi afet duyarlılık haritalarında 20 m çözünürlük kullanılmaktadır. Bu tez kapsamında da tüm faktörler Obruk Teknik Kılavuzuna (Arik vd., 2023) benzer olarak 20 m *20 m piksel boyutunda oluşturulmuştur.

3.2 Faktör Seçimi

Bölüm 2.4'te bilgiler doğrultusunda VIF ve TOL değerleri kullanılan tüm koşullandırma faktörleri için ayrı ayrı hesaplanmıştır. Obruk koşullandırma faktörlerinden yükseklik ve ortalama su buharı basıncı faktörlerinin çoklu bağlanım problemine sahip olduğu belirlenmiştir (Çizelge 3.2).


Bir sonraki aşamada ise pearson korelasyon katsayısı matrisi yöntemi ile ilk aşamada çoklu bağlanım problemine sahip faktörler karşılaştırılmıştır. Bu amaçla ilk olarak Pearson korelasyon matrisi eşik değeri için ise literatürde yaygın olarak kullanılan +0,75 ve -0,75 değeri girilerek veri setindeki korelasyon analizi hesaplanmıştır (Şekil 3.1). Korelasyon analizinde ortalama su buhar basıncı ile ortalama sıcaklık arasında pozitif korelasyon ve yükseklik ile ortalama sıcaklık ve ortalama su buhar basıncı arasında negatif korelasyona sahip olduğu belirlenmiştir. Çoklu bağlanım problemine sahip her bir faktör ayrı ayrı veri setinden çıkartılarak model performansına katkısı hesaplanmış ve ortalama su buhar basıncı ve ortalama sıcaklık faktörleri veri setinden ayıklanarak korelasyon analizi, VIF ve TOL değerleri yeniden hesaplanmıştır (Şekil 3.2 ve Çizelge 3.3) VIF ve TOL değerleri ile Korelasyon eşik değeri üzerinden ya da altında bir değer bulunmaması nedeniyle analiz tamamlanmıştır. Faktör seçim analizi sonucunda yükselik, eğim, bakı, ortalama yağış, elektriksel iletkenlik, arazi kullanımı, litoloji, volkanik formlara yakınlık, yeraltı su seviyesi değişim hızı, yola yakınlık, yerleşim alanlarına yakınlık, su yüzeylerine yakınlık, faylara yakınlık, TWI, SPI, NDVI ve akarsuya yakınlık olmak üzere toplamda 18 faktör seçilmiştir

Çizelge 3.2. Koşullandırma faktörlerine ait VIF ve TOL değerleri.


Koşullandırma Faktörleri	VIF	TOL	Çoklu Bağlılık Problemi
Yükseklik	79.11	0.18	Var
Ortalama Sicaklık	4.47	0.22	Var
Ortalama yagis	2.28	0.43	Yok
Volkanlara Yakınlık	2.26	0.44	Yok
Litoloji	1.85	0.53	Yok
Su Yüzeylerine Yakınlık	1.70	0.58	Yok
Yerlesime Yakınlık	1.70	0.58	Yok
Ort Su Buhar Basıncı	78.57	0.59	Var
Arazi Kullanımı	1.65	0.60	Yok
Yola Yakınlık	1.60	0.62	Yok
Eğim	1.56	0.63	Yok
Kuyu Yoğunluğu	1.48	0.67	Yok
Faya Yakınlık	1.43	0.69	Yok
Akarsuya Yakınlık	1.43	0.69	Yok
Yeraltı su seviyesi değişim hızı	1.42	0.70	Yok
NDVI	1.35	0.73	Yok
TWI	1.26	0.79	Yok
SPI	1.14	0.87	Yok
Elektriksel İletkenlik	1.13	0.87	Yok
Baki	1.03	0.96	Yok

Çizelge 3.3. Yüksek VIF ve TOL değerlerine sahip faktörler çıkarıldıktan sonraki VIF ve TOL değerleri.

Koşullandırma Faktörleri	VIF	TOL	Çoklu Bağlılık Problemi
Yükseklik	3.30	0.30	Yok
Volkanik formlara yakınlık	2.72	0.37	Yok
TWI	2.45	0.41	Yok
Yağış	2.15	0.47	Yok
Yeraltı su seviyesi değişim hızı	1.93	0.52	Yok
Eğim	1.84	0.54	Yok
Su yüzeylerine yakınlık	1.71	0.59	Yok
Faylara yakınlık	1.66	0.60	Yok
Kuyu yoğunluğu	1.60	0.63	Yok
Akarsuya yakınlık	1.56	0.64	Yok
Yerleşim alanlarına yakınlık	1.55	0.65	Yok
Litoloji	1.52	0.66	Yok
Yola yakınlık	1.39	0.72	Yok
Elektriksel iletkenlik	1.31	0.77	Yok
NDVI	1.27	0.79	Yok
Arazi kullanımı	1.21	0.83	Yok
SPI	1.12	0.89	Yok
Bakı	1.04	0.96	Yok



Şekil 3.1. Tüm koşullandırma faktörlerine ait pearson korelasyon matrisi.



Şekil 3.2. Yüksek korelasyona sahip faktörler çıkarıldıktan sonra oluşturulan pearson korelasyon matrisi.

3.3 Modelin Oluşturulması

3.3.1 Hiperparametrelerin optimizasyonu

Model hiperparametrelerinin, model tahmin sonuçlarının en iyi ve veri setine en uygun olarak seçilmesi için çapraz doğrulama yöntemini kullanan GridSearchCV yöntemi tercih edilmiştir. Çizelge 3.4'te MÖ modellerine ait en iyi performans sonuçlarını veren ayarlanmış hiperparametreler ve sayısal değerleri gösterilmektedir.

Çizelge 3.4. Sınıflandırma algoritmaları ve en uyumlu hiperparametre değerleri.

Algoritma	Hiperparametreler	Hiperparametre açıklaması	En Uygun Değer
AdaBoost	Öğrenme oranı	Her ağacın eğitim öğrenme oranı	1.0
	n_estimators	Algoritmadaki Karar ağacı sayısı	100
CatBoost	Derinlik	Karar ağacının maksimum derinliği	6
	İterasyon	Modelin kaç ağaçtan oluşacağını belirtir	300
	Öğrenme Oranı	Her ağacın eğitim öğrenme oranı	0.1
RF	n_estimator (Tahminci)	RF'deki karar ağacı sayısı	100
	Maksimum öznelik	Her bir bölme işleminde kullanılacak öznelik sayısı	Auto
	Maksimum derinlik	Karar ağacının maksimum derinliği	None
	Faktör	Bölme işlemini gerçekleştirecek fonksiyon. (Gini, Entropi)	gini
XGBoost	Öğrenme oranı	Her ağacın eğitim öğrenme oranı	0.2
	Colsample_bytree	Algoritmadaki her ağaca karşılık gelen sütunların alt örnek oranı	0.9
	n_estimators	Algoritmadaki Karar ağacı sayısı	100
	Maksimum derinlik	Her ağacın maksimum derinliğini kontrol eder	5
	Min_child_weight	Ağaç Bölümleme adımı	1
	Alt örnek	Algoritmanın ağaçlar büyümeden önce aşırı uyumu engellemek amacıyla kullandığı alt örnek oranı	0.8
LightGBM	n_estimators	Algoritmadaki Karar ağacı sayısı	100
	Öğrenme Oranı	Her ağacın eğitim öğrenme oranı	0.1
	Maksimum derinlik	Her ağacın minimum derinliğini belirtir.	3

3.3.2 Modellerin performans sonuçları

Modelin performansı kullanılan algoritmanın yapısı, koşullandırma faktörleri ve bu faktörlerin kendi aralarındaki ilişkiye bağlı olarak değişmektedir. Her bir MÖ modelinden elde edilen hata matrisleri, doğruluk kesinlik duyarlılık f-1 skoru hesaplamak için kullanılan doğru pozitifler (tp), doğru negatifler (tn), yanlış pozitifler


(fp) ve yanlış negatifleri (fn) bulmak için kullanılmıştır. Buna göre algoritmalara ait tüm performans metrik skorları Çizelge 3.5'te verilmiştir.

Çizelge 3.5. Hiperparametre uyumlandırılması yapılmış algoritmaların hata matrislerinden hesaplanan performans sonuçları.

Algoritmalar	Doğruluk	Kesinlik	Hassaslık	F1 Skoru
Random Forest	0.973579	0.988534	0.956156	0.950923
XGBoost	0.955018	0.961934	0.956306	0.952741
LGBM	0.957579	0.98448	0.961712	0.949568
AdaBoost	0.968175	0.973812	0.967267	0.963141
CatBoost	0.965614	0.957637	0.967267	0.954977

Çizelge 3.5'teki sonuçlar incelendiğinde, Tüm MÖ modelleri performans metriklerinde çok yüksek (%95) değerler elde etmişlerdir. Buna göre; RF (0.973579, 0.988534), doğruluk ve kesinlik metriklerinde, AdaBoost (0.967267) ve CatBoost (0.967267), hassaslık metriğinde ve son olarak AdaBoost (0.963141), f-1 skoru metriğinde diğer MÖ modellerine göre daha iyi performans vermişlerdir. Tüm performans değerleri birbirine yakın değerler gösterdiğinden dolayı en iyi performansı gösteren algoritmayı belirlemek zordur.

Ancak tüm MÖ modelleri birbirine çok yakın ve çok yüksek skorlar (%90 ve üzeri) elde etmişlerdir. Bu nedenle hata matrisleri ile obruk ve obruk olmayan veriler üzerindeki tahminler karşılaştırılmıştır. Hata matrislerinde RF, 188 obruk numunesinden 175'ini (%93) ve 189 obruk olmayan örneklemden 186'sını (%98), doğru etmiş AdaBoost ise 188 obruk numunesinden 179'unu (%95) ve 189 obruk olmayan numuneden 180 (%95) doğru tahmin etmişlerdir (Şekil 3.3).




Şekil 3.3. Algoritmalarla ait hata matrislerinin karşılaştırılması.

Bu kapsamda Performans metrikleri ve hata matrisleri göz önüne alındığında, diğer MÖ modellerine göre daha başarılı değerler gösteren RF modeli, obruk duyarlılık haritası için en uygun yöntem olarak tercih edilmiştir. Bu kapsamda RF modeline ait faktör önem dereceleri (FO), Çizelge 3.6’da sunulmuştur. Oluşturulan modelde sırasıyla yeraltı su seviyesi değişim hızı, yükseklik, kuyu yoğunluğu, volkanik formlara yakınlık faktörleri en çok öneme sahipken yola yakınlık, arazi kullanımı ve bakı ise en az öneme sahip faktörlerdir.

Çizelge 3.6. Koşullandırma faktörlerine ait önem oranları.

Koşullandırma Faktörleri	Faktör Önem Oranları (%)
Yeraltı su seviyesi değişim hızı	12.96
Yükseklik	7.27
Kuyu yoğunluğu	6.85
Volkanik Formlara Yakınlık	6.22
TWI	4.23
Litoloji	4.06
Yağış	3.97
Su yüzeylerine yakınlık	2.46
Elektriksel İletkenlik	2.13
Akarsuya yakınlık	1.13
Faylara Yakınlık	0.94
SPI	0.92
Yerleşim alanlarına yakınlık	0.70
Eğim	0.58
NDVI	0.43
Yola Yakınlık	0.35
Arazi Kullanımı	0.35
Baki	0.29


Koşullandırma faktörlerine ait önem oranları grafiği Şekil 3.4’te gösterilmiştir.



Şekil 3.4. Faktör önem oranları grafiği.


FO, tek başına obruk duyarlılık modelini açıklamak için yeterli değildir. Bu amaçla her bir faktörün obruk tahminine etkisini açıklanması için SHAP değerlerini gösteren kısmi bağımlılık grafikleri üretilmiştir (Şekil 3.5, Şekil 3.6 ve Şekil 3.7). Bu grafiklerdeki noktalar obruk olan numunelerin ürettiği SHAP değerlerini göstermektedir. Kısmi bağımlılık grafiğindeki faktörün shap değeri pozitif ise obruk oluşumunu pozitif yönde etki ettiğini negatif değer ise obruk oluşumunu negatif bir etkisi olduğunu göstermektedir (İban ve Bilgilioglu, 2023). Şekil 3.5a incelendiğinde Yeraltı su seviyesi değişim hızı yıllık değişim -2 metreden fazla olan yerlerde obruk oluşumu pozitif yönde artmıştır. Elektriksel iletkenlik, 0-2000 (S/cm) aralığında yoğunlaştığı görülmektedir (Şekil 3.5b). Bu durumda yeraltı suyunun daha asidik karakterde olacağı için çözünmeyi arttıracak ve ortamdaki suyun daha az tuzlu olduğu için tarımsal sulamanın yoğun olduğu fikrini verebilir. Faylara yakınlık faktörü incelendiğinde, obruklar 0-5000 metre arasında yoğunlaşmaktadır (Şekil 3.5c). Ortalama yağış SHAP değerine göre, ortalama yağışın 35 mm olduğu dönemlerde obruk oluşma riskinin arttığı görülmektedir (Şekil 3.5d). Volkanik formlara yakınlık faktörü incelendiğinde, volkanik formlara yakınlaştıkça obruk oluşumunun arttığını

göstermektedir (Şekil 3.5e). Litoloji SHAP değerlerine göre; kuvaterner yaşlı alüvyonlarda (QAL), Mezozoyik yaşlı kireçtaşlarında (MsKç) ve Neojen yaşlı kireçtaşı birimleri obruk oluşumuna pozitif etki ettiği görülmüştür (Şekil 3.5f).




Şekil 3.5. Jeolojik ve iklimsel faktörlere ait kısmi bağımlılık grafikleri

Şekil 3.6'daki çevresel ve antropojenik faktörlerin grafiklerine göre; arazi kullanımı için çayır-mera (30) ve tarım alanlarında (40) (Şekil 3.6a), NDVI için bitki örtüsünün az olduğu alanlarda (Şekil 3.6b), su yüzeylerine yakınlık için belirli bir yoğunlaşma olmamakla birlikte yaklaşık 10.000 metre mesafede (Şekil 3.6c), yollara yakınlık için 0-2000 metre arasında yola yakın alanlarda (Şekil 3.6e), yerleşim alanlarına yakınlık için 0-5000 metre mesafede yerleşimlere yakın alanlarda (Şekil 3.6d) ve son olarak kuyu yoğunluğu SHAP değeri için kuyu yoğunluğu arttıkça obruk oluşumuna pozitif etki ettiği söylenebilir (Şekil 3.6f).



Şekil 3.6. Çevresel ve Antropojenik faktörlere ait kısmi bağımlılık grafikleri

Topoğrafik faktörlerin kısmi bağımlılık grafiklerine göre; Akarsuya yakınlık için 0-2000 metre mesafede akarsu ağına yakın alanlarda obruk oluşumuna etki ettiği görülmektedir (Şekil 3.7a). Yükseklik için, obrukların 950-1250 metre aralığında yoğunlaştığı sonrasında ise belirgin bir değişimin olmadığı (Şekil 3.7b), eğim için 0-10 derece arasında düşük eğimli ya da düz alanlarda obruk oluşumuna pozitif etki ettiği gözlemlenmiştir (Şekil 3.7e). TWI değerinin artmasıyla obruk oluşumu arasında pozitif yönde bir ilişki olduğu dolayısıyla yeraltı su seviyesi yüksek alanların diğer alanlara göre obruk duyarlılığının yüksek olduğu söylenebilir (Şekil 3.7c). SPI ve baki faktörünün obruk oluşumuna belirgin bir katkısı yoktur (Şekil 3.7d, Şekil 3.7f).



Şekil 3.7. Topoğrafik faktörlere ait kısmi bağımlılık grafikleri

3.3.3 Konya kapalı havzası obruk duyarlılık haritası

Performansı en yüksek olan RF modeli tüm çalışma alanında (106728811 piksel) uygulanmış ve tüm çalışma alanı için obruk duyarlılık indeks haritası üretilmiştir. Elde edilen indeks haritası doğal kırılım yöntemine göre çok düşük, düşük orta, yüksek ve çok yüksek olmak üzere 5 sınıfa ayrılarak obruk duyarlılık haritası elde edilmiştir (Şekil 3.8).

yaklaşık %72'si yüksek ve çok yüksek derece duyarlı alanlarda bulunmaktadır. Bu kapsamda makro ölçekte çalışılan bir alanda oluşturulan obruk duyarlılık haritasının yüksek derece doğruluğa sahip olduğu söylenebilir.

Çizelge 3.7. Duyarlılık sınıflarına göre obruk envanterinin yüzdesel oranları.

Duyarlılık Sınıfları	Obruk Envanteri	Yüzdesel Dağılım
Çok düşük derece duyarlı	4	0.65 %
Düşük derece duyarlı	14	2.29 %
Orta derece duyarlı	154	25.16 %
Yüksek derece duyarlı	242	39.54 %
Çok yüksek derece duyarlı	198	32.35 %

4. TARTIŞMA VE SONUÇLAR

KKH'da karapınar ve civarında Özdemir (2015) tarafından yapılan çalışmada bölgenin kuzeyinde yeralan Eşeli-Kanlankaç yayları arası, Yelekli mahallesi, Yaşova, Yazkumca yaylası ve Halil yurdu yayları yüksek derece duyarlı olup üretilen duyarlılık haritası ile örtüşmektedir ancak güney kısmında yer alan hotamış, yeniceoba kamışağıl yayları ile batıda yer alan kuzukuyu ve demiryalı yayları düşük derece duyarlı olarak gösterilmiştir. Bu alanlar duyarlılık haritasında genellikle orta derece duyarlı ve yer yer yüksek derece duyarlı olarak modellenmiştir. Bu çalışmada kullanılan faktörlerden yeraltı su seviyesi değişimi, faya yakınlık, litoloji ve yükseklik gibi faktörler, her iki haritada obruk oluşumunda etkili faktörler olarak bulunmuştur. Oluşturulan iki farklı duyarlılık haritasında da farklı tür ve ölçekte koşullandırma faktörleri kullanılmıştır. Ayrıca bölgede yapılan çalışmalarda volkanizma etkisinde çok baskın bir etkiye sahip olmasına rağmen diğer çalışmada kullanılmaması nedeniyle bu farkın oluştuğu düşünülmektedir.

Havzada yapılan diğer bir çalışma Sarı (2017) tarafından AHP yöntemi kullanılarak Konya şehir merkezi Karaman ve Aksaray illerinin bir kısmında içerisinde barındıran alanda oluşturulan obruk duyarlılık haritasıdır. Bu çalışmada, jeoloji arazi kullanımı ve obruk konumlarının yüksek faktör önem oranında sahip olduğu belirtilerek Karapınar ilçesinin kuzeybatısında yer alan Başaran ve Beştaşlı yayları arasında kalan yaklaşık 438 km²'lik (toplam alanın %18'i) bir alanın yüksek derece duyarlı olduğu belirtilmiştir. Sarı (2017) Karapınarın batı ve kuzeybatı civarındaki alanları yüksek duyarlı diğer alanları ise orta derece duyarlı hesaplamıştır. Bu tez çalışmasında ise Karapınarın batısı ve kuzey batısındaki alanlar yüksek ve çok yüksek olmakla birlikte bir kısmı örtüşmekte ancak diğer çalışmada orta derece duyarlı alanlar, bu çalışmada yüksek ve çok yüksek duyarlı olarak gösterilmektedir. Çalışmalar arasındaki farklılıklar kullanılan obruk envanteri ve koşullandırma faktörlerinden kaynaklanmaktadır. Sarı (2017) obrukların mekânsal konumlarını koşullandırma faktörü değerlendirerek toplamda 8 faktör ve yaklaşık 200 adet obruk verisi kullanmış ve bu faktörlerden; litoloji, arazi kullanımı ve obruk yoğunluğu faktörlerinin ağırlıkları fazladır. Sarı (2017) tarafından yapılan çalışmada obruk yoğunluğu önemli bir faktördür ve buna bağlı olarak bu alanlarda yüksek duyarlı alanların olması beklenir ancak obrukların yoğun olmadığı alanlarda çalışmanın eksik kaldığı düşünülmektedir.

Bu tez çalışmasında 628 adet envanter ve 18 koşullandırma faktörü kullanılmış olup çalışma alanı olarak KKH tamamı baz alınmıştır. Her iki çalışmada da kullanılan metodoloji ve koşullandırma faktörleri farklıdır.

KKH’da diğer bir çalışmada Orhan vd. (2020) AHP yöntemi ile Karapınar çevresini ve alt havzaları sınırlayan alanların toplam %40’ının yüksek (%25) ve çok yüksek derece duyarlı (%15) alanlar içerisinde kaldığını belirtmişlerdir. Bu tez çalışmasında ise yüksek (20) ve çok yüksek (19) duyarlı alanlar toplam alanın toplam %39’una tekabül etmektedir. Çalışmada jeoloji, YSS değişikliği, kuyu yoğunluğu, deformasyon, faylara olan uzaklık ve yağış parametrelerinin duyarlılığı daha fazla etkilediği tespit etmişlerdir. Özellikle Karapınar şehir merkezi ve batısının çok düşük derece duyarlı, şehir merkezinin kuzey-kuzeybatı istikametindeki alanların Özdemir (2015), tarafından yapılan çalışmaya benzer şekilde yüksek derece duyarlı olarak hesaplanmıştır. Bu tez çalışmasında ise benzer şekilde yüksek ve çok yüksek derece duyarlı alanlar örtüşmekte ancak düşük ve çok düşük derece duyarlı olarak hesaplanan Karapınar şehir merkezi yüksek batısında kalan alan ise orta ve yüksek derece duyarlı olarak hesaplanmıştır. Jeoloji, YSS değişimi, kuyu yoğunluğu, faylara olan uzaklık ve yağış benzer olarak bu çalışmada da obruk oluşumuna etkili bir faktör olarak karşımıza çıkmaktadır. Sarı (2017) ve Orhan vd. (2020) tarafından çalışmaya benzer olarak obrukların mekânsal konumlarını koşullandırma faktörü olarak kullanmıştır. Her iki çalışmada da obruk yoğunluğu ya da deformasyonların faktör önemleri diğer faktörlere göre fazladır. Dolayısıyla bu alanlarda yüksek ve çok yüksek duyarlı olarak çıkması muhtemeldir. Sarı (2017) ve Orhan vd. (2020) çalışmasında eksik noktalar benzer olarak obrukların olmadığı alanlarda eksik kalmasıdır. Bu tez çalışmasında ise volkanik formların etkisi alanda etkili bir faktör önemine sahip olması sebebiyle diğer bahse konu çalışmalardan ayrılmaktadır.

Arik vd. (2023) Konya merkezli çalışmasında MÖ yöntemi kullanılarak obruk duyarlılık haritası üretmişlerdir. Bu çalışmada toplanan 41 adet koşullandırma faktörü çoklu bağlantı problemi testi yapıldıktan sonra 28’e düşürülerek bir model oluşturulmuştur. Üretilen modelde koşullandırma faktörlerinin SHAP değerleri hesaplanarak; Faylara yakınlık, Kalsiyum değişimi, Bikarbonat değişimi kalsit ve yeraltı su seviyesi değişimi gibi parametlerin değerleri yüksek, bakı, arazi kullanımı ve drenajlara yakınlık gibi faktörler ise düşük puan almıştır. Bu tez çalışmasında ise

benzer olarak yeraltı su seviyesi değişimi yüksek, Bakı ve arazi kullanımı ise düşük SHAP değerine sahiptir. Ancak faylara yakınlık ve litoloji gibi faktörler nispeten diğer çalışmaya göre düşük derecede öneme sahiptir. Her iki modelde kullanılan faktörler; sayısal olarak ve çalışma alanı olarak birbirinden farklıdır. Ayrıca ilk çalışmada su kimyası analizleri ile ilgili birçok hidrojeolojik parametre kullanılırken bu tez çalışmasında ise bu faktörler kullanılmamış ve volkanik alanlara yakınlık faktörü diğer çalışmadan farklı olarak kullanılmıştır. Her iki modelde de Karapınar, Ereğli, Altınekin Sarayönü ve Kadınhanı ilçeleri benzer derece duyarlı ancak Konya il merkezi ilk çalışmada orta derece bazı alanlarda ise yüksek derece duyarlı olarak hesaplanmıştır. Bu çalışmada ise bahse konu alanlar düşük derece duyarlı olarak hesaplanmıştır. İlk çalışmada volkanik formlara yakınlık faktörü, kullanılmamış olup bu çalışmada ise önemli bir faktör olarak hesaplanmaktadır. Her iki duyarlılık modelinde de temel olarak farklı bir yaklaşım ve koşullandırma faktörleri kullanılmasına rağmen yüksek oranda örtüşmektedir.

KKH, oluşumu itibarıyla neotektonik süreçlerden etkilenecek oluşan tipik bir horst graben yapısındadır. Obruklar bu tektonik hareketlerin etkisiyle aktif ve örtülü fayların etrafında kümelenmiştir. Ayrıca bölgede gözlemlenen CO₂ gazı çıkışlarının alandaki volkanik formlarla etkisiyle ilişkili olabileceği bu sebeple de yeraltı suyuna asidik karakter kazandırarak karbonatların çözünmesini hızlandırabileceği düşünülmektedir. Obrukların kümелendiği alanlarda iklim, çöl iklimi tipindedir. Dolayısıyla alanda meydana gelen yağışların az olması, yeraltı suyuna olan baskıyı artırarak çevresel-antropojenik faktörleri tetiklemiş, karstlaşma sürecine bir çarpan etkisi yaratmıştır. Sonuç olarak makro ölekte ve farklı formatlardaki verilerle üretilen obruk duyarlılık haritası temelde bölgede yapılan çalışmalara çoğu oranda benzer kısmen de farklılıklar göstermektedir. Çalışma alanının geniş olması ve kullanılan faktörler temelde bu kısmi farklılıkların temel sebebidir. Bu tez çalışması kapsamında üretilen duyarlılık modeli ile KKH'sının tamamını kapsayacak makro ölekte bir çalışma alanı ile ele alınarak literatürdeki önemli bir açığıda kapatmamıza fırsat vermiştir.

KAYNAKLAR

- Abbas, Q., Ali, T., Asad, A. T. ve Aslam, M., 2024. Analyzing the impact of geosynthetic reinforcement on Sinkhole: A numerical investigation with machine learning approach, *Engineering Failure Analysis*, 157, 107915.
- Abelson, M., Baer, G., Shtivelman, V., Wachs, D., Raz, E., Crouvi, O., Kurzon, I. ve Yechieli, Y., 2003. Collapse-sinkholes and radar interferometry reveal neotectonics concealed within the dead sea basin, *Geophysical Research Letters*, 30, 10, 2-10.
- Acero, P., Auqué, L. F., Galve, J. P., Gutiérrez, F., Carbonel, D., Gimeno, M. J., Yechieli, Y., Asta, M. P. ve Gómez, J. B., 2015. Evaluation of geochemical and hydrogeological processes by geochemical modeling in an area affected by evaporite karstification, *Journal of Hydrology*, 529, 1874–1889.
- Admassu, Y. ve Celestine W., 2021. Improved automated mapping of sinkholes using high-resolution DEMs, *Environmental & Engineering Geoscience*, 27, 3, 331–351.
- Afet ve Acil Durum Yönetimi Başkanlığı (AFAD), (2023). 2022 Yılı doğa kaynaklı olay istatistikleri, Ankara.
- Akıncı, H., Doğan, S., Kılıçoğlu, C. ve Keçeci, S. B., 2010. Samsun il merkezinin heyelan duyarlılık haritasının üretilmesi, *Harita Teknolojileri Elektronik Dergisi*, 2, 3, 3–27.
- Amin, P., Ghalibaf, M. A., Mermut, A. R., Delavarkhalafi, A. ve Latifi, M. A., 2023. Prediction of sinkhole hazard using artificial intelligence model with soil characteristics and GPR data in arid alluvial land in Central Iran, *Environmental Earth Sciences*, 82, 15, 1–19.
- Arabameri, A., Pradhan, B. ve Bui, D. T., 2020. Spatial modelling of gully erosion in the Ardebil River Watershed using three statistical-based techniques, *Catena*, 190, 669-686.
- Arık, F., Bilgilioglu, S. S., İban, M. A., Delikan, A., Göçmez, G., Döyen, A., Kansun, G., Gezin, C., Bilgilioglu, H. ve Dülger, A., 2023. Obruk teknik klavuz, Paradigma Akademi Yayınları, Konya.
- Ayday, C. ve Alan, H., 2020. Eskişehir–Sivrihisar YHT güzergahında obruk oluşumu ve riskleri hakkında rapor, Jeoloji Mühendisleri Odası Yayınları, Ankara.
- Aydın, H. E. ve İban, M. C., 2023. Predicting and analyzing flood susceptibility using boosting-based ensemble machine learning algorithms with shapley additive explanations, *Natural Hazards*, 116, 3, 2957-2991.
- Badola, S., Mishra, V. N. ve Parkash, S., 2023. Landslide susceptibility mapping using XGBoost machine learning method, 2023 International Conference on Machine Intelligence for Geoanalytics and Remote Sensing, Hyderabad, India, IEEE, 1-4.

- Barka, A. ve Reilinger, R., 1997. Active tectonics of the Eastern Mediterranean region: deduced from GPS, neotectonic and seismicity data, *Anatoli Dı Geofisico*, 40, 3, 587, 610.
- Bausilio, G., Corona, M. A., Di Martire, D., Guerriero, L., Tufano, R., Calcaterra, D. ve Francioni, M., 2022. Comparison of two machine learning algorithms for anthropogenic sinkhole susceptibility assessment in the city of Naples (Italy), 1112-1123, Lancellotta, R., Viggiani, C., Flora, A., Silva, F. ve Mele, L. (Editör), *Geotechnical Engineering for the Preservation of Monuments and Historic Sites III*, CRC Press, Londra, İngiltere.
- Bayari, C. S., Pekkan, E. ve Ozyurt, N. N., 2009. Obruks, as giant collapse dolines caused by hypogenic karstification in central Anatolia, Turkey: Analysis of likely formation processes, *Hydrogeology Journal*, 17, 2, 327.
- Bianchini, S., Confuorto, P., Intrieri, E., Sbarra, P., Di Martire, D., Calcaterra, D. ve Fanti, R., 2022. Machine learning for sinkhole risk mapping in guidonia-bagni di tivoli plain (rome), Italy, *Geocarto International*, 37, 27, 16687-16715.
- Bianchini, S., Solari, L., Del Soldato, M., Raspini, F., Montalti, R., Ciampalini, A. ve Casagli, N., 2019. Ground subsidence susceptibility (GSS) mapping in Grosseto Plain (Tuscany, Italy) based on satellite InSAR data using frequency ratio and fuzzy logic, *Remote Sensing*, 11, 17, 2015.
- Bilgilioğlu, S. S. ve Bilgilioğlu, H., 2023. Aksaray ili obruk duyarlılık haritasının coğrafi bilgi sistemleri (CBS) ve analitik hiyerarşi süreci (AHS) yöntemleri ile oluşturulması, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12, 2, 612-625.
- Bordbar, M., Rezaie, F., Bateni, S. M., Jun, C., Kim, D., Busico, G. ve Valipour, M., 2023. Global review of modification, optimization, and improvement models for aquifer vulnerability assessment in the era of climate change, *Current Climate Change Reports*, 9, 4, 45-67.
- Boualla, O., Mehdi, K. ve Zourarah, B., 2016. Collapse dolines susceptibility mapping in Doukkala Abda (Western Morocco) by using GIS matrix method (GMM), *Modeling Earth Systems and Environment*, 2, 1-18.
- Breiman, L., 2001. Random forests, *Machine Learning*, 45, 5-32.
- Brinkmann, R., Parise, M. ve Dye, D., 2008. Sinkhole distribution in a rapidly developing urban environment: Hillsborough County, Tampa Bay Area, Florida, *Engineering Geology*, 99, 3, 169-184.
- Bruno, E., Calcaterra, D. ve Parise, M., 2008. Development and morphometry of sinkholes in coastal plains of Apulia, southern Italy, Preliminary sinkhole susceptibility assessment, *Engineering Geology*, 99, 3, 198-209.
- Bui, D. T., Panahi, M., Shahabi, H., Singh, V. P., Shirzadi, A., Chapi, K. ve Ahmad, B. B., 2018. Novel hybrid evolutionary algorithms for spatial prediction of floods, *Scientific Reports*, 8, 1, 1-14.

- Calligaris, C., Devoto, S., Galve, J., Zini, L. ve Pérez Peña, J., 2017. Integration of multi-criteria and nearest neighbour analysis with kernel density functions for improving sinkhole susceptibility models: The case study of Enemonzo (NE Italy), *International Journal of Speleology*, 46, 2, 191-204.
- Caramanna, G., Ciotoli, G. ve Nisio, S., 2008. A review of natural sinkhole phenomena in Italian plain areas, *Natural Hazards*, 45, 2, 145-172.
- Chai, L., Xie, X., Wang, C., Tang, G. ve Song, Z., 2024. Ground subsidence risk assessment method using PS-InSAR and LightGBM: a case study of shanghai metro network, *International Journal of Digital Earth*, 17, 1, 2297842.
- Chen, T. ve Guestrin, C., 2016. XGBoost: A scalable tree boosting system, *Proceedings of the 22nd ACM SIGKD International Conference on Knowledge Discovery And Data Mining*, ACM, San Fransisko, ABD, 785-794.
- Cheng, Q., Jie, L. I. U., Zhiwei, Y. A. N. G., Zhang, T. ve Bin, W. A. N. G., 2024. Avalanche susceptibility evaluation of the Kezhayi to Gongnaisi section of the Duku expressway, *The Chinese Journal of Geological Hazard and Control*, 35, 1, 60-71.
- Ciotoli, G., Di Loreto, E., Finoia, M. G., Liperi, L., Meloni, F., Nisio, S. ve Sericola, A., 2016. Sinkhole susceptibility, Lazio region, central Italy, *Journal of Maps*, 12, 2, 287-294.
- Corwin, D. L. ve Yemoto, K., 2020. Salinity: Electrical conductivity and total dissolved solids, *Soil Science Society of America Journal*, 84, 5, 1442-1461.
- Coşkun, B., Parlar, Ş. ve Eren, Y., 2021. Karapınar (Konya) bölgesinin neotektonik özellikleri, 1. Uluslararası Mühendislik Bilimleri ve Multidisipliner Yaklaşımlar Kongresi, İstanbul, Bildiriler Kitabı, 534.
- Çetinkaya, S. ve Kocaman, S., 2022. Snow avalanche susceptibility mapping for Davos, Switzerland, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 1083-1090.
- Çörekçioğlu, İ., 1994. Karapınar kuzeyi obruklar sahası karst hidrojeolojisi incelemesi, DSİ 4. Bölge Müdürlüğü, Konya.
- Doctor, D. H. ve Doctor, K. Z., 2012. Spatial analysis of geologic and hydrologic features relating to sinkhole occurrence in Jefferson County, West Virginia, *Carbonates and Evaporites*, 27, 143-152.
- Dorogush, A. V., Ershov, V. ve Gulin, A., 2018. CatBoost: Gradient boosting with categorical features support, *arXiv preprint arXiv:1810*, 11363.
- Drobinina, E., Kovaleva, T. ve Koriakina, A., 2020. The local variation of the overlying soils geotechnical properties in the karst susceptibility assessment, *Carbonates and Evaporites*, 35, 3, 79.

- Dursun, Y. G., 2022. Sultanhanı (Aksaray) ovası ve çevresinin hidrojeolojik, hidrokimyasal ve izotopik özelliklerinin incelenmesi, Doktora Tezi, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü, Aksaray.
- Elmahdy, S. I. ve Mostafa, M. M., 2013. Natural hazards susceptibility mapping in Kuala Lumpur, Malaysia: An assessment using remote sensing and geographic information system (GIS), *Geomatics, Natural Hazards and Risk*, 4, 1, 71-91.
- Elmahdy, S. I., Mohamed, M. M., Ali, T. A., Abdalla, J. E. D. ve Abouleish, M., 2022. Land subsidence and sinkholes susceptibility mapping and analysis using random forest and frequency ratio models in Al Ain, UAE, *Geocarto International*, 37, 1, 315-331.
- Emre, Ö., Duman, T. Y., Özalp, S., Elmacı, H., Olgun, Ş. ve Şaroğlu, F., 2013. Active fault map of Turkey with explanatory text, General Directorate Of Mineral Research And Exploration, Special Publication Series-30, 495-529.
- Emre, Ö., Duman, T. Y., Özalp, S., Şaroğlu, F., Olgun, Ş., Elmacı, H. ve Çan, T., 2018. Active fault database of Turkey, *Bulletin of Earthquake Engineering*, 16, 8, 3229-3275.
- Esposito, C., Belcecchi, N., Bozzano, F., Brunetti, A., Marmoni, G. M., Mazzanti, P. ve Spizzirri, M., 2021. Integration of satellite-based A-DInSAR and geological modeling supporting the prevention from anthropogenic sinkholes: A case study in the Urban Area of Rome, *Geomatics, Natural Hazards and Risk*, 12, 1, 2835-2864.
- Fanos, A. M., Pradhan, B., Alamri, A. ve Lee, C. W., 2020. Machine learning-based and 3d kinematic models for rockfall hazard assessment using LiDAR data and GIS, *Remote Sensing*, 12, 11, 1755.
- Fanos, A. M., Pradhan, B., Mansor, S., Yusoff, Z. M. ve Abdullah, A. F. B., 2018. A hybrid model using machine learning methods and GIS for potential rockfall source identification from airborne laser scanning data, *Landslides*, 15, 1833-1850.
- Fetullah, A., Dülger, A., Bilgilioğlu, S. S., İban, M. C., Delikan, A., Göçmez, G., Döyen, A., Kansun, G., Gezgün, C. ve Bilgilioğlu, H., 2023. Obruk teknik kılavuz, Paradigma Akademi Yayınları, Çanakkale.
- Galve, J. P., Bonachea, J., Remondo, J., Gutiérrez, F., Guerrero, J., Lucha, P. ve Sánchez, J. A., 2008. Development and validation of sinkhole susceptibility models in mantled karst settings, a case study from the Ebro Valley evaporite karst (NE Spain), *Engineering Geology*, 99, 3, 185-197.
- Galve, J. P., Gutiérrez, F., Remondo, J., Bonachea, J., Lucha, P. ve Cendrero, A., 2009a. Evaluating and comparing methods of sinkhole susceptibility mapping in the Ebro Valley evaporite karst (NE Spain), *Geomorphology*, 111, 3, 160-172.
- Galve, J. P., Gutiérrez, F., Lucha, P., Guerrero, J., Bonachea, J., Remondo, J. ve Cendrero, A., 2009b. Probabilistic sinkhole modelling for hazard assessment, *Earth Surface Processes and Landforms*, 34, 3, 437-452.

- Gao, Y. ve Alexander, E. C., 2008. Sinkhole hazard assessment in Minnesota using a decision tree model, *Environmental Geology*, 54, 945-956.
- Gezgin, C., 2022. The influence of groundwater levels on land subsidence in Karaman (Turkey) using the PS-InSAR technique, *Advances in Space Research*, 70, 11, 3568-3581.
- Göçmez, G., Dülger, A., Arık, F., Delikan, A., Coşkun, B., Kansun, G. ve Arslan, Ş., 2022. Ürünli (Çumra-Konya) çevresinde yeraltı suyu seviye değişimleri ve obruk oluşumları, *Selçuk Üniversitesi Sosyal ve Teknik Araştırmalar Dergisi*, 20, 172-178.
- Gutiérrez, F. ve Cooper, A. H., 2002. Evaporite dissolution subsidence in the historical city of Calatayud, Spain: Damage appraisal and prevention, *Natural Hazards* 25, 3, 259–88.
- Gutiérrez, F., 2016. Sinkhole hazards, *Oxford Research Encyclopedia of Natural Hazard Science*, URL Adres: <https://oxfordre.com/naturalhazardscience/display/10.1093/acrefore/9780199389407.001.0001/acrefore-9780199389407-e-40>, Erişim tarihi: 21.10.2024.
- Gutierrez, F., Cooper, A. H. ve Johnson, K. S., 2008a. Identification, prediction, and mitigation of sinkhole hazards in evaporite karst areas, *Environmental Geology*, 53, 1007-1022.
- Gutiérrez, F., Guerrero, J. ve Lucha, P., 2008b. A genetic classification of sinkholes illustrated from evaporite paleokarst exposures in Spain, *Environmental Geology* 53, 5, 993–1006.
- Günay, G., Çörekçioğlu, İ. ve Övül, G., 2011. Geologic and hydrogeologic factors affecting sinkhole (obruk) development in Central Turkey, *Carbonates and Evaporites*, 26, 1, 3-9.
- Ha, H., Bui, Q. D., Tran, D. T., Nguyen, D. Q., Bui, H. X. ve Luu, C., 2024. Improving the forecast performance of landslide susceptibility mapping by using ensemble gradient boosting algorithms, *Environment, Development and Sustainability*. URL Adres: <https://link.springer.com/article/10.1007/s10668-024-04694-3#citeas>, Erişim tarihi: 21.10.2024.
- Hyland, S. E., Kennedy, L. M., Younos, T. ve Parson, S., 2006. Analysis of sinkhole susceptibility and karst distribution in the northern Shenandoah Valley, Virginia: Implications for low impact development (LID) site suitability models, *Special Report SR31-2006*, Virginia Water Resources Research Center, Virginia, ABD.
- İban, M. C. ve Bilgilioglu, S. S., 2023. Snow avalanche susceptibility mapping using novel tree-based machine learning algorithms (XGBoost, NGBoost, and LightGBM) with Explainable Artificial Intelligence (XAI) approach, *Stochastic Environmental Research and Risk Assessment*, 37, 6, 2243–2270.

- Karag zel, R., Mahmutođlu, Y., Top uođlu, M. E., Őans, G. ve Dikbaő, A., 2020. Susceptibility mapping for sinkhole occurrence by GIS and SSI methods: A case study in Afsin-Elbistan coal basin, Pamukkale  niversitesi M hendislik Bilimleri Dergisi, 26, 8, 1353-1359.
- Karaman, M. E., 1986. Altmekin (Konya)  evresinin jeolojisi ve tektonik evrimi, Bulletin of the Geological Society of Turkey, 29, 157-170.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W. ve Liu, T. Y., 2017. Lightgbm: A highly efficient gradient boosting decision tree, 31st International Conference on Neural Information Processing Systems (2017), California, ABD, Book of Proceedings, Volume I, 3149-3157.
- Ketin,  . I., 1968. T rkiye'nin genel tektonik durumu ve baőlıca deprem b lgeleri arasındaki iliőkiler, Maden Tetkik ve Arama Dergisi 71, 129-34.
- Kidanu, S. T., Anderson, N. L. ve Rogers, J. D., 2018. Using GIS-based spatial analysis to determine factors influencing the formation of sinkholes in Greene County, Missouri, Environmental & Engineering Geoscience, 24, 3, 251-261.
- Kim, K., Kim, J., Kwak, T. Y. ve Chung, C. K., 2018. Logistic regression model for sinkhole susceptibility due to damaged sewer pipes, Natural Hazards, 93, 765-785.
- Kim, Y. J., Nam, B. H., Jung, Y. H., Liu, X., Choi, S., Kim, D. ve Kim, S., 2022. Probabilistic spatial susceptibility modeling of carbonate karst sinkhole, Engineering Geology, 306, 106728.
- Kim, Y. J., Nam, B. H. ve Youn, H., 2019. Sinkhole detection and characterization using LiDAR-derived DEM with logistic regression, Remote Sensing, 11, 13, 1592.
- Kim, Y. J., Nam, B. H., Lim, C., Jung, H. S. ve Moon, J. S., 2018. A decision tree based hazard assessment of karst sinkholes, International Foundations Congress & Equipment Expo, Florida, ABD, Book of Proceedings, Volume I, 43-53.
- Kim, Y. J., Nam, B. H., Shamet, R., Soliman, M. ve Youn, H., 2020. Development of sinkhole susceptibility map of East Central Florida, Natural Hazards Review, 21, 4, 04020035.
- Ko yiđit, A., 1984. G neybatı T rkiye ve yakın dolayında levha i i yeni tektonik geliőim, T rkiye Jeoloji Kurumu B lteni, 27, 1, 1-15.
- Kowalski, R., 2011. Computational logic and human thinking: How to be artificially intelligent, Cambridge University Press, Londra, İngiltere.
- Lindsey, B. D., Katz, B. G., Berndt, M. P., Ardis, A. F. ve Skach, K. A., 2010. Relations between sinkhole density and anthropogenic contaminants in selected carbonate aquifers in the Eastern United States, Environmental Earth Sciences, 60, 1073-1090.

- Lumongsod, R. M. G., Ramos, N. T. ve Dimalanta, C. B., 2022. Mapping the karstification potential of Central Cebu, Philippines using GIS, *Environmental Earth Sciences*, 81, 18, 449.
- Malalha, S. A. K., Burhanuddin, M. ve Yunos, N. B. M., 2024. Unveiling the tapestry of machine learning: a comparative analysis of support vector machines, random forests, and neural networks in diverse applications, *Journal of Propulsion Technology*, 45, 3, 973-979.
- Michelena, M. D., Kilian, R., Baeza, O., Rios, F., Rivero, M. Á., Mesa, J. L. ve Acevedo, R. D., 2020. The formation of a giant collapse caprock sinkhole on the Barda Negra plateau basalts (Argentina): Magnetic, mineralogical and morphostructural evidences, *Geomorphology*, 367, 107297.
- Mohammady, M., Pourghasemi, H. R., Amiri, M. ve Tiefenbacher, J. P., 2021. Spatial modeling of susceptibility to subsidence using machine learning techniques, *Stochastic Environmental Research and Risk Assessment*, 1-12.
- Mohd Rosdi, M. A. H., Abd Latif, Z., Othman, A. N. ve Nasir, N. M., 2019. Sinkhole susceptibility hazard zones using GIS framework and heuristic method, advances in remote sensing and geo informatics applications, *Proceedings of the 1st Springer Conference of the Arabian Journal of Geosciences (CAJG-1)*, Hammamet, Tunisia, Book of Proceedings, 261-264.
- Nalbantçılar, M. T., Arık, F. ve Diken, A., 2009. Konya Kapalı Havzasının mevcut sorunları ve çözüm önerileri, *TMMOB Jeoloji Mühendisleri Odası Haber Bülteni*, 78-81.
- Nazik, L. ve Poyraz, M., 2015. Gelişiminde, karstlaşmanın iklim değişikliklerinin önüne geçtiği Tektono-Karstik bir iç havza: Konya Kapalı Ovası, *Ulusal Jeomorfoloji Sempozyumu*, Samsun, Bildiriler Kitabı, 15-17.
- Nefeslioglu, H. A., Tavus, B., Er, M., Ertugrul, G., Ozdemir, A., Kaya, A. ve Kocaman, S., 2021. Integration of an INSAR and ANN for sinkhole susceptibility mapping: A case study from Kirikkale-Delice (Turkey), *ISPRS International Journal of Geo-Information*, 10, 3, 119.
- Orhan, O., Kırtıloğlu, O. S. ve Yakar, M., 2020a. Konya kapalı havzası obruk envanter bilgi sisteminin oluşturulması, *Geomatik*, 5, 2, 81-90.
- Orhan, O., Yakar, M. ve Ekercin, S., 2020b. An application on sinkhole susceptibility mapping by integrating remote sensing and geographic information systems, *Arabian Journal of Geosciences*, 13, 1-17.
- Ölmez, M. ve Saraç, D., 2009. Su ürünleri için PH'nın önemi, *Ziraat Mühendisliği*, 353, 12-17.
- Özdemir, A., 2015a. Investigation of sinkholes spatial distribution using the weights of evidence method and GIS in the vicinity of Karapınar (Konya, Turkey), *Geomorphology*, 245, 40-50.

- Özdemir, A., 2015b. Sinkhole susceptibility mapping using a frequency ratio method and GIS technology near Karapınar, Konya-Turkey, *Procedia Earth and Planetary Science*, 15, 502–506.
- Özdemir, A., 2016. Sinkhole susceptibility mapping using logistic regression in Karapınar (Konya, Turkey), *Bulletin of Engineering Geology and the Environment*, 75, 2, 681–707.
- Pedregosa, F., Varoquaux, G., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A. ve Cournapeau, D., 2011. Scikit-learn: Machine learning in python, *Journal of Machine Learning Research*, 12, 2825-2830.
- Perrin, J., Cartannaz, C., Noury, G. ve Vanoudheusden, E., 2015. A multicriteria approach to karst subsidence hazard mapping supported by weights-of-evidence analysis, *Engineering Geology*, 197, 296-305.
- Polat, S., 2011. Türkiye’de traverten oluşumu, yayılış alanı ve korunması, *Marmara Coğrafya Dergisi*, 23, 389-428.
- Pourghasemi, H. R., Jirandeh, A. G., Pradhan, B., Xu, C. ve Gokceoglu, C., 2013. Landslide susceptibility mapping using support vector machine and GIS at the Golestan Province, Iran, *Journal of Earth System Science*, 122, 349-369.
- Pradhan, B., Abokharima, M. H., Jebur, M. N. ve Tehrany, M. S., 2014. Land subsidence susceptibility mapping at Kinta Valley (Malaysia) using the evidential belief function model in GIS, *Natural Hazards*, 73, 1019-1042.
- Prathapchandran, K. ve Janani, T., 2021. A trust aware security mechanism to detect sinkhole attack in RPL-based IoT environment using random forest–RFTRUST, *Computer Networks*, 198, 108413.
- Qiu, X., Wu, S. S. ve Chen, Y., 2020. Sinkhole susceptibility assessment based on morphological, imagery, and contextual attributes derived from GIS and imagery data, *Journal of Cave and Karst Studies*, 82, 1, 1-17.
- Rahman, M., Chen, N., Islam, M. M., Mahmud, G. I., Pourghasemi, H. R., Alam, M. ve Dewan, A., 2021. Development of flood hazard map and emergency relief operation system using hydrodynamic modeling and machine learning algorithm, *Journal of Cleaner Production*, 311, 127594.
- Rosdi, M. A. H. M., Othman, A. N., Zubir, M. A. M., Latif, Z. A. ve Yusoff, Z. M., 2017. Sinkhole susceptibility hazard zones using GIS and analytical hierarchical process (AHP): A case study of Kuala Lumpur and Ampang Jaya, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 145-151.
- Sarı, F. ve Yalçın, M., 2023. Maximum entropy model-based spatial sinkhole occurrence prediction in Karapınar, Turkey, *Kuwait Journal of Science*, 50, 1, 1–15.

- Sarı, F., 2017. Sinkhole susceptibility analysis for Karapınar/Konya via multi criteria decision, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 4, 339–43.
- Sarı, F., Kahveci, M., Somay-Altas, M. ve Tuşat, E., 2021. Evaluating sinkhole formation with multicriteria decision analysis: a case study in Karapınar-Konya, Turkey, *Arabian Journal of Geosciences*, 14, 1-15.
- Singha, C., Rana, V. K., Pham, Q. B., Nguyen, D. C. ve Łupikasza, E., 2024. Integrating machine learning and geospatial data analysis for comprehensive flood hazard assessment, *Environmental Science and Pollution Research*, 31, 35, 48497-48522.
- Song, K. I., Cho, G. C. ve Chang, S. B., 2012 Identification, remediation, and analysis of karst sinkholes in the longest railroad tunnel in South Korea, *Engineering Geology*, 135, 92-105.
- Subedi, P., Subedi, K., Thapa, B. ve Subedi, P., 2019. Sinkhole susceptibility mapping in Marion County, Florida: Evaluation and comparison between analytical hierarchy process and logistic regression based approaches, *Scientific Reports*, 9, 1, 7140.
- Sun, D., Chen, D., Zhang, J., Mi, C., Gu, Q. ve Wen, H., 2023. Landslide susceptibility mapping based on interpretable machine learning from the perspective of geomorphological differentiation, *Land*, 12, 5, 1018.
- Sun, D., Wang, J., Wen, H., Ding, Y., Gu, Q., Zhang, J. ve Zhang, F., 2024. Insights into landslide susceptibility in different karst erosion landforms based on interpretable machine learning, *Earth Surface Processes and Landforms*, 49, 3, 1006-1027.
- Süzen, M. L. ve Doyuran, V., 2004 A comparison of the GIS based landslide susceptibility assessment methods: Multivariate versus bivariate, *Environmental Geology*, 45, 665-679.
- T.C. Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü (SYGM), (2018). Konya Kapalı Havzası Yönetim Planı: Havza Koruma Eylem Planlarının Nehir Havzası Yönetim Planlarına Dönüştürülmesi için Teknik Yardım, Konya Kapalı Havzası Yönetim Planı, Ankara. URL Adres: <https://www.tarimorman.gov.tr/SYGM/Belgeler/NHYP%20DEN%C4%B0Z/KONYA%20KAPALI%20NEH%C4%B0R%20HAVZASI%20Y%C3%96NET%C4%B0M%20PLANI.pdf>, Erişim tarihi: 09.09.2024.
- Taheri, K., Gutiérrez, F., Mohseni, H., Raeisi, E. ve Taheri, M., 2015. Sinkhole susceptibility mapping using the analytical hierarchy process (AHP) and magnitude–frequency relationships: A case study in Hamadan province, Iran, *Geomorphology*, 234, 64-79.
- Taheri, K., Missimer, T. M., Mohseni, H., Fidelibus, M. D., Fathollahy, M. ve Taheri, M., 2021. Enhancing spatial prediction of sinkhole susceptibility by mixed waters geochemistry evaluation: application of ROC and GIS, *Environmental Earth Sciences*, 80, 1-28.

- Taheri, K., Shahabi, H., Chapi, K., Shirzadi, A., Gutiérrez, F. ve Khosravi, K., 2019. Sinkhole susceptibility mapping: A comparison between Bayes-based machine learning algorithms, *Land Degradation & Development*, 30, 7, 730-745.
- Tehrany, M. S., Pradhan, B. ve Jebur, M. N., 2013. Spatial prediction of flood susceptible areas using rule based decision tree (DT) and a novel ensemble bivariate and multivariate statistical models in GIS, *Journal of Hydrology*, 504, 69-79.
- Tharp, T. M., 2002. Poroelastic analysis of cover-collapse sinkhole formation by piezometric surface drawdown, *Environmental Geology*, 42, 5, 447-56.
- Tien Bui, D., Tuan, T. A., Klempe, H., Pradhan, B. ve Revhaug, I., 2016. Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree, *Landslides*, 13, 361-378.
- Todd, A. L. ve Ivey-Burden, L., 2015. A method of mapping sinkhole susceptibility using a geographic information system: a case study for interstates in the karst counties of Virginia, 14th Sinkhole Conference, Florida, ABD, Book of Proceedings, 299-306.
- Türk, K., Güner, N., Barbaros, E. Yılmaz, N. P., Sülükçü, S., Yelezer, L., Ateş, Ş., Mutlu, G., Sertel, N., Keleş, S., Çınar, A., Demirbaş, Ş., Toksoy, T., Özgür, C., Yavuz, S., Avcı, K., Özerk, C. ve Bulut, A. 2012. Konya havzası'nda karstik çöküntü alanlarının belirlenmesi ve tehlike değerlendirmesi, 65. Türkiye Joloji Kurultayı, Ankara, Bildiri Özleri Kitabı, 240-241.
- Veress, M. ve Unger, Z., 2015. Kab Mountain: Karst under a basalt cap, 55-62, Lóczy D. (Editör), *Landscapes and Landforms of Hungary*, Springer, Berlin, Almanya.
- Wang, G., Hao, J., Wen, H. ve Cao, C., 2022. A random forest model of karst ground collapse susceptibility based on factor and parameter coupling optimization, *Geocarto International*, 37, 27, 15548-15567.
- Wang, X., Wang, L., Zhang, W., Zhang, C., Tan, C., Yan, P. ve Guo, J., 2022. Ground fissure susceptibility mapping based on factor optimization and support vector machines, *Bulletin of Engineering Geology and the Environment*, 81, 8, 341.
- Wei, A., Li, D., Zhou, Y., Deng, Q. ve Yan, L., 2021. A novel combination approach for karst collapse susceptibility assessment using the analytic hierarchy process, catastrophe, and entropy model, *Natural Hazards*, 105, 405-430.
- Whitman, D., Gubbels, T. ve Powell, L., 1999. Spatial interrelationships between lake elevations, water tables, and sinkhole occurrence in central Florida: A GIS approach, *Photogrammetric Engineering and Remote Sensing*, 65, 10, 1169-1178.
- Wu, Y., Jiang, X., Guan, Z., Luo, W. ve Wang, Y., 2018. AHP-based evaluation of the karst collapse susceptibility in Tailai Basin, Shandong Province, China, *Environmental Earth Sciences*, 77, 1-14.

- Xie, Y. H., Zhang, B. H., Liu, Y. X., Liu, B. C., Zhang, C. F. ve Lin, Y. S., 2022. Evaluation of the karst collapse susceptibility of subgrade based on the AHP method of ArcGIS and prevention measures: A case study of the Quannan expressway, section k1379+ 300-k1471+ 920, Water, 14, 9, 1432.
- Yechieli, Y., Abelson, M. ve Baer, G., 2016. Sinkhole formation and subsidence along the Dead Sea coast, Israel, Hydrogeology Journal, 24, 3, 601.
- Yilmaz, I., Marschalko, M. ve Bednarik, M., 2013. An assessment on the use of bivariate, multivariate and soft computing techniques for collapse susceptibility in GIS environ, Journal of Earth System Science, 122, 371-388.
- Youssef, A. M. ve Pourghasemi, H. R., 2021. Landslide susceptibility mapping using machine learning algorithms and comparison of their performance at Abha Basin, Asir Region, Saudi Arabia, Geoscience Frontiers, 12, 2, 639-655.
- Yu, H., Arabameri, A., Costache, R., Crăciun, A. ve Arora, A., 2022. Land subsidence susceptibility assessment using advanced artificial intelligence models, Geocarto International, 37, 27, 18067-18093.
- Zhang, J., Ma, X., Zhang, J., Sun, D., Zhou, X., Mi, C. ve Wen, H., 2023. Insights into geospatial heterogeneity of landslide susceptibility based on the SHAP-XGBoost model, Journal of Environmental Management, 332, 117357.
- URL- 1 <https://tr.wikipedia.org/wiki/Konya_kapalı_havzası>, Erişim tarihi: 24.03.2024.
- URL-2 <<https://www.britannica.com/technology/artificial-intelligence>>, Erişim tarihi: 21.03.2024
- URL-3 <<https://scikit-learn.org/stable/modules/ensemble.html#adaboost>>, Erişim tarihi: 03.05.2024.
- URL-4 <<https://xgboost.readthedocs.io/en/stable/tutorials/model.html>>, Erişim tarihi: 03.04.2024.
- URL-5 <https://scikit-learn.org/stable/modules/cross_validation.html#>, Erişim tarihi: 04.04.2024.
- URL-6 <https://scikitlearn.org/stable/modules/generated/sklearn.model_selection.RandomizedSearchCV.html>, Erişim tarihi: 29.05.2024.

ÖZGEÇMİŞ

Adı ve Soyadı : İbrahim ÇETİN

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Cumhuriyet Üniversitesi, Jeofizik Mühendisliği Bölümü, 2003-2009

Yüksek Lisans : Aksaray Üniversitesi, Jeodezi ve Coğrafi Bilgi Sistemleri Anabilim Dalı, 2022-2024

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Kongrelerde Sunulan Makaleler

1. Çetin, İ. ve Bilgilioğlu, S. S., 2024. Aksaray ilinde meydana gelen obrukların tektonizma ile ilişkisinin araştırılması, 7. Uluslararası Mühendislik Bilimleri ve Multidisipliner Yaklaşımlar Kongresi, İstanbul, Bildiriler Kitabı, 519.