

**T.C.
ISPARTA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ
TOPRAK BİLİMİ VE BİTKİ BESLEME ANABİLİM DALI**

**SAYISAL TOPRAK HARİTALAMA ÇALIŞMALARINDA
KULLANILAN FARKLI YAKLAŞIMLARIN
KARŞILAŞTIRILMASI VE SAYISAL DEĞİŞKENLER İLE
TOPRAK ÖZELLİKLERİ ARASINDAKİ İLİŞKİLERİN
ARAŞTIRILMASI: ATABEY OVASI ÖRNEĞİ**

Fuat KAYA

**Danışman
Prof. Dr. Levent BAŞAYİĞİT**

ISPARTA- 2021



© 2021 [Fuat KAYA]

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR DİZİNİ	x
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	4
2.1. Geleneksel Toprak Haritalama Çalışmaları	4
2.2. Sayısal Toprak Haritalama Çalışmaları	9
2.3. Sayısal Toprak Haritalamada Kullanılan Çeşitli Çevresel Değişkenler	10
2.3.1. Toprak	11
2.3.2. Organizmalar	12
2.3.3. Ana materyal	15
2.3.4. Topoğrafya	17
2.3.5. İklim	20
2.4. Kategorik Toprak Sınıflarının Sayısal Haritalanmasına Yönelik Çalışmalar	20
2.4.1. Denetimli öğrenme algoritmaları	21
2.4.1.1. Lojistik regresyon algoritması kullanılarak yapılan sayısal toprak haritalama çalışmaları	22
2.4.1.2. Farklı sınıflandırma algoritmaları kullanılarak yapılan sayısal toprak haritalama çalışmaları	34
2.4.2. Denetimsiz öğrenme algoritmaları	41
2.4.3. Bilgi temelli sınıflandırma	47
2.5. Toprak Özelliklerini Tahmin Etmeye Yönelik Çalışmalar	47
3. MATERYAL VE YÖNTEM	54
3.1. Materyal	54
3.1.1. Çalışma Alanı	56
3.1.2. Kullanılan çevresel değişkenler	58
3.1.2.1. Topoğrafik çevresel değişkenler	58
3.1.2.2. Uydu görüntüsünden üretilen çevresel değişkenler	60
3.1.2.2.1. Landsat 7 ETM+ uydu görüntüsü	60
3.1.2.2.2. Sentinel 2A MSI uydu görüntüsü	63
3.1.3. Mevcut toprak haritasından veri alınması	65
3.2. Yöntem	66
3.2.1. Toprak sınıflarının denetimli sınıflandırma ile sayısal haritalanması	66
3.2.1.1. Çok terimli lojistik regresyon	66
3.2.1.2. Doğruluk değerlendirmesi	69
3.2.2. Toprak sınıflarının denetimsiz sınıflandırma ile sayısal haritalanması	72
3.2.4. Toprak özellikleri ile çevresel değişkenler arasındaki ilişkilerin belirlenmesi	76
4. BULGULAR VE TARTIŞMA	80
4.1. Çok Terimli Lojistik Regresyon (MNLR)	80
4.1.1. Ordo düzeyinde toprakların sayısal olarak haritalanması	80
4.1.2. Alt ordo düzeyinde toprakların sayısal olarak haritalanması	89
4.1.3. Büyük grup düzeyinde toprakların sayısal olarak haritalanması	94
4.1.4. Alt grup düzeyinde toprakların sayısal olarak haritalanması	100

4.1.5. Seri düzeyinde toprakların sayısal olarak haritalanması	109
4.1.6. FAO-WRB sınıflandırma düzeyinde toprakların sayısal haritalanması.....	121
4.2. K Ortalama	127
4.2.1. K değerinin 4 olması durumunda oluşan sayısal harita	128
4.2.2. K değerinin 5 olması durumunda oluşan sayısal harita	130
4.2.3. K değerinin 8 olması durumunda oluşan sayısal harita	132
4.2.4. K değerinin 10 olması durumunda oluşan sayısal harita	134
4.2.5. K değerinin 20 olması durumunda oluşan sayısal harita	135
4.3. Denetimli ve Denetimsiz Sınıflandırma Algoritmalarının Karşılaştırılması	138
4.4. Bilgi Temelli Sınıflandırma	139
4.5. Toprak Özellikleri ile Çevresel Değişkenler Arasındaki İlişkiler.....	140
4.5.1. Tanımlayıcı istatistikler.....	141
4.5.2. Çoklu doğrusal regresyon ile belirli toprak özelliklerinin tahmini	146
4.5.2.1. Toprak kil içeriğinin çevresel değişkenlerle tahmini	146
4.5.2.2. Toprak organik madde içeriğinin çevresel değişkenlerle tahmini	148
4.5.2.3. Katyon değişim kapasitesi içeriğinin çevresel değişkenlerle tahmini.....	150
4.5.2.4. Kum içeriğinin çevresel değişkenlerle tahmini	152
4.5.3. Temel bileşenler analizi	154
5. SONUÇ VE ÖNERİLER	159
KAYNAKLAR	165
EKLER.....	186
EK A. Toprak örnekleri analiz sonuçları	187
EK B. Laboratuvar analizleri görselleri	192
ÖZGEÇMİŞ	193

ÖZET

Yüksek Lisans Tezi

SAYISAL TOPRAK HARİTALAMA ÇALIŞMALARINDA KULLANILAN FARKLI YAKLAŞIMLARIN KARŞILAŞTIRILMASI VE SAYISAL DEĞİŞKENLER İLE TOPRAK ÖZELLİKLERİ ARASINDAKİ İLİŞKİLERİN ARAŞTIRILMASI: ATABEY OVASI ÖRNEĞİ

Fuat KAYA

**Isparta Uygulamalı Bilimler Üniversitesi
Lisansüstü Eğitim Enstitüsü
Toprak Bilimi ve Bitki Besleme Anabilim Dalı**

Danışman: Prof. Dr. Levent BAŞAYİĞİT

Bu çalışma, sayısal toprak haritalama metodolojisi ile toprak sınıflarının tahmin edilebilirliği ve mekânsal haritalarının oluşturulmasında kullanılan farklı yöntemlerin kullanılabilirliğinin, mevcut verileri bulunan örnek bir alanda test edilmesini kapsamaktadır. Kategorik toprak sınıflarının haritalanması, genel sınıflandırma alanına giren bir karar verme sürecidir. Bu sebeple, makine öğrenme alanında sınıflandırma amaçlı kullanılan Çok terimli lojistik regresyon algoritması kullanılmıştır. Denetimli öğrenme algoritması olarak tanımlanan bu algoritma ile mevcut eğitim setinden öğrenilen sınıf modelleri ile alanda mekânsal haritalar üretilmiş ve doğrulukları değerlendirilmiştir. Denetimsiz öğrenme algoritmalarından olan K-ortalama algoritması çevresel değişkenlerin birlikteliğinin sonucu olarak toprak sınıflarının oluşumunun meydana gelebileceği alanları tanımlamak amaçlı uygulanmıştır. Son olarak sahadan elde edilen toprak verileri ile güncel uydu görüntüsü ve sayısal yükseklik modelinden elde edilen çevresel değişkenler arasında çoklu doğrusal regresyon modelleri kullanılarak toprak özellikleri ile çevresel değişkenler arasındaki ilişkiler ortaya konulmaya çalışılmıştır. Toprak özellikleri ile çevresel değişkenler arasındaki mevcut ilişkileri anlamlandırabilmek ve yorumlayabilmek için temel bileşenler analizi yürütülmüştür. Çalışma sonucunda denetimli sınıflandırma sonucu üretilen toprak sınıf haritalarının daha yüksek doğruluklara sahip olduğu belirlenmiştir. Elde edilen dijital toprak haritaları, geleneksel anlamda kullanılan mevcut toprak haritalarının kullanım şekline farklı olarak dijital tarım sistemlerine girdi olarak kullanılabilecek nitelikli veriler olabilir.

Anahtar Kelimeler: Sayısal toprak haritalama, Çevresel değişken, Modelleme, Toprak özellikleri, Toprak sınıflarının tahmini, Çok terimli lojistik regresyon

2021, 194 sayfa

ABSTRACT

M.Sc. Thesis

COMPARISON OF DIFFERENT APPROACHES USED IN DIGITAL SOIL MAPPING AND RESEARCHING THE RELATIONSHIP BETWEEN DIGITAL VARIABLES AND SOIL PROPERTIES: A CASE STUDY OF ATABEY PLAIN

Fuat KAYA

**Isparta University of Applied Sciences
The Institute of Graduate Education
Department of Soil Science and Plant Nutrition**

Supervisor: Prof. Dr. Levent BAŞAYIĞIT

This study includes testing the predictability of soil classes with digital soil mapping methodology and the usability of different methods used in creating spatial maps in a sample area with available data. Mapping of categorical soil classes is a decision-making process that falls within the field of general classification. For this reason, a multinomial logistic regression algorithm, which is used for classification in machine learning, has been used. Using this algorithm, which is defined as a supervised learning algorithm, spatial maps were produced in the field with soil class models learned from the existing training set and their accuracy was evaluated. The K-means algorithm, one of the unsupervised learning algorithms, has been applied to define the areas where the formation of soil classes may occur as a result of the combination of environmental variables. Finally, by using multiple linear regression models between the soil data obtained from the field and the environmental variables obtained from the current satellite image and digital elevation model, the relationships between soil properties and environmental variables were tried to be revealed. In order to understand and interpret the existing relationships between soil properties and environmental variables, principal component analysis was conducted. As a result of the study, it was determined that soil class maps produced as a result of supervised classification have higher accuracy. The digital soil maps obtained can be qualified data that can be used as input to digital agriculture systems, different from the way the existing soil maps are used traditionally.

Key Words: Digital soil mapping, Environmental covariates, Modelling, Soil properties, Prediction of soil classes, Multinomial logistic regression

2021, 194 pages

TEŞEKKÜR

Çalışma konusunun seçiminde geniş projeksiyonu ile beni bu alana yönlendiren, modelden elde edilen sonuçların pedolojik yorumlamalarında engin tecrübesi ile yön veren, çözüm odaklı yaklaşımları ile bu süreçte katkılarından dolayı tez danışmanım sayın Prof. Dr. Levent BAŞAYIĞIT'e, Uydu görüntülerinin işlenmesi aşamasında desteklerinden dolayı sayın hocam Doç. Dr. Mert DEDEOĞLU'na, teşekkürlerimi sunarım.

Matematiksel ve istatistiksel uygulamaların R programında yürütülmesi sürecinde model sonuçlarının yorumlanmasında değerli yorumları ile katkı sunan Sergen CANSIZ'a, BTK Akademi tarafından ücretsiz olarak sunulan yapay zekâ ve makine öğrenme konuları ile ilgili kurslara erişebilme olanağı sağladığı için Bilişim Teknolojileri Kurumu'na teşekkür ediyorum.

2019-YL1-0044 No`lu Proje ile tezimi maddi olarak destekleyen Isparta Uygulamalı Bilimler Üniversitesi Bilimsel Araştırma Projeleri Yönetim Birimi Başkanlığı'na teşekkür ederim.

Eğitim-öğretim hayatım süresince maddi ve manevi katkılarından dolayı Babam, Annem ve Kardeşlerim olmak üzere tüm aile fertlerime ve tez çalışmalarımın yoğun süreçlerinde hep yanımda olan eşim Emel'e teşekkür ederim.

Fuat KAYA
ISPARTA, 2021

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Spektral ve mekansal çözünürlük	13
Şekil 3.1. Çalışma alanı mevcut toprak haritası sınıflandırma seviyeleri	56
Şekil 3.2. Çalışma alanı yer buldur haritası	57
Şekil 3.3. Atabey ilçesi toprak sıcaklık ve toprak nem rejimi diyagramı	57
Şekil 3.4. Çok terimli lojistik regresyon metodu ile toprak sınıflarının sayısal haritalanması iş akışı	71
Şekil 3.5. K ortalamaları algoritması ile toprak sınıflarının sayısal haritalanması iş akışı	74
Şekil 3.6. Bilgi temelli yaklaşım ile toprak sınıflarının sayısal haritalanması iş akışı	75
Şekil 3.7. Toprak özellikleri ile çevresel değişkenler arasındaki ilişkilerin belirlenmesi iş akışı	79
Şekil 4.1. Landsat 7 ETM+ uydu görüntüsünden üretilen çevresel değişkenler	81
Şekil 4.2. Sayısal yükseklik modelinden üretilen çevresel değişkenler	82
Şekil 4.3. Ordo düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi	84
Şekil 4.4. Ordo düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri	84
Şekil 4.5. Ordo seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları	85
Şekil 4.6. Alt ordo düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi ...	91
Şekil 4.7. Alt ordo düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri	91
Şekil 4.8. Alt ordo seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları	93
Şekil 4.9. Büyük grup düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi	96
Şekil 4.10. Büyük grup düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri	97
Şekil 4.11. Büyük grup seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları	99
Şekil 4.12. Alt grup düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi	101
Şekil 4.13. Alt grup düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri	106
Şekil 4.14. Alt grup seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları	107
Şekil 4.15. Alt grup seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları	108
Şekil 4.16. Seri düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri	116
Şekil 4.17. Seri düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi	117
Şekil 4.18. Seri seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları ..	118
Şekil 4.19. Seri seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları ..	119
Şekil 4.20. FAO-WRB 2.düzy sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri	125
Şekil 4.21. FAO-WRB 2.düzy düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi	125

Şekil 4.22. FAO-WRB 2. seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları	126
Şekil 4.23. K ortalama algoritması ordo düzeyinde toprak sınıfları haritası	130
Şekil 4.24. K ortalama algoritması büyük grup düzeyinde toprak sınıfları haritası	132
Şekil 4.25. K ortalama algoritması 8 sınıflı sayısal haritası.....	133
Şekil 4.26. K ortalama algoritması 10 sınıflı sayısal haritası.....	134
Şekil 4.27. K ortalama algoritması 20 sınıflı sayısal haritası.....	136
Şekil 4.28. Kural ifadeleri sonucu oluşturulan ordo haritası.....	140
Şekil 4.29. Sentinel 2A-MSI uydu görüntüsünden üretilen çevresel değişkenler....	142
Şekil 4.30. Toprak özellikleri ile topoğrafik çevresel değişkenler arasındaki korelasyon grafiği	144
Şekil 4.31. Toprak özellikleri ile spektral çevresel değişkenler arasındaki korelasyon grafiği	145
Şekil 4.32. Kil tahmininde modelde kullanılan değişkenlerin göreceli önemi	147
Şekil 4.33. Organik madde tahmininde modelde kullanılan değişkenlerin göreceli önemi	149
Şekil 4.34. Katyon değişim kapasitesi tahmininde modelde kullanılan değişkenlerin göreceli önemi	151
Şekil 4.35. Kum içeriğinin tahmininde modelde kullanılan değişkenlerin önem seviyesi	153
Şekil B.1. Laboratuvar analizleri görselleri	192

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Çalışma alanı topraklarının sınıflandırılması.....	55
Çizelge 3.2. Sayısal yükseklik modelinden üretilen çevresel değişkenler.....	59
Çizelge 3.3. Landsat 7 ETM+ uydusu mekânsal ve spektral çözünürlük bilgileri	61
Çizelge 3.4. Uydu görüntülerinden üretilen çevresel değişkenler	64
Çizelge 3.5. Sentinel 2A-MSI uydusu mekânsal ve spektral çözünürlük bilgileri	64
Çizelge 3.6. Toprak örneklerinde yapılan analizler	65
Çizelge 4.1. Ordo düzeyi toprak sınıflarının tahmininde model değişken katsayıları	83
Çizelge 4.2. Ordo düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi	83
Çizelge 4.3. Alt ordo düzeyi toprak sınıflarının tahmininde model değişken katsayıları	90
Çizelge 4.4. Alt ordo düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi.....	90
Çizelge 4.5. Büyük grup düzeyi toprak sınıflarının tahmininde model değişken katsayıları	95
Çizelge 4.6. Büyük grup düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi.....	96
Çizelge 4.7. Alt grup düzeyi toprak sınıflarının tahmininde model değişken katsayıları	102
Çizelge 4.8. Alt grup düzeyi toprak sınıflarının tahmininde model değişken katsayıları	103
Çizelge 4.9. Alt grup düzeyinde toprak sınıflandırma sonuçlarının eğitim seti karışım matrisi.....	104
Çizelge 4.10. Alt grup düzeyinde toprak sınıflandırma sonuçlarının test seti karışım matrisi	105
Çizelge 4.11. Seri düzeyi toprak sınıflarının tahmininde model değişken katsayıları.....	111
Çizelge 4.12. Seri düzeyi toprak sınıflarının tahmininde model değişken katsayıları.....	112
Çizelge 4.13. Seri düzeyi toprak sınıflarının tahmininde model değişken katsayıları.....	113
Çizelge 4.14. Seri düzeyinde toprak sınıflandırma sonuçlarının eğitim seti karışım matrisi	114
Çizelge 4.15. Seri düzeyinde toprak sınıflandırma sonuçlarının test seti karışım matrisi	115
Çizelge 4.16. FAO - WRB 2. düzey toprak sınıflarının tahmininde model değişken katsayıları.....	123
Çizelge 4.17. FAO - WRB 2. düzey toprak sınıflandırma sonuçlarının karışım matrisi	124
Çizelge 4.18. K ortalama algoritması ordo düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi.....	129
Çizelge 4.19. K ortalama algoritması büyük grup düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi.....	131
Çizelge 4.20. Ordo sınıfları için kural ifadeleri	139
Çizelge 4.21. Toprak analiz sonuçları ve çevresel değişkenlerin tanımlayıcı istatistikleri.....	143
Çizelge 4.22. Kil içeriği tahmininde model değişken katsayıları	146

Çizelge 4.23. Organik Madde içeriği tahmininde model değişken katsayıları	148
Çizelge 4.24. Katyon Değişim kapasitesi tahmininde model değişken katsayıları	151
Çizelge 4.25. Kum içeriği tahmininde model değişken katsayıları	153
Çizelge 4.26. Temel bileşenler analizinin ilk dokuz bileşeninin varyans açıklama yüzdeleri.....	155
Çizelge 4.27. Temel bileşenler analizi sonucu elde edilen bileşenlerin faktör yükleri	158
Çizelge A.1. Toprak örnekleri analiz sonuçları	187



SİMGELER VE KISALTMALAR DİZİNİ

AfSIS	Afrika Toprak Bilgi Hizmeti
BME	Bayesian maksimum entropi
BRT	Güçlendirilmiş regresyon ağaçları
CarInd	Karbonat indeksi
CART	Sınıflandırma ve regresyon ağaçları
CBS	Coğrafi bilgi sistemleri
CI	Karışıklık indeksi
CT	Sınıflandırma ağacı
CV	Varyasyon katsayısı
DT	Karar ağacı
EM	Elektromanyetik indüksiyon
EVI	Geliştirilmiş bitki örtüsü indeksi
GEE	Google earth engine
GSI	Tane büyüklük indeksi
ha	Hektar
IDE	Tümleşik geliştirme ortamı
ISODATA	Yinelemeli kendini düzenleyen veri analizi tekniği
KDKÖ	Kısa dalga kızılötesi
KNN	K-en yakın komşu
LR	Lojistik regresyon
LS	Eğim uzunluğu faktörü
LUCAS	Arazi kullanımı ve kapsama alanı çerçeve araştırması
LVQ	Vektör niceleme modelleri
m	Metre
MESMA	Çoklu son üye spektral karışım analizi
MIDII	Orta kızılötesi indeks
MNB	Çok terimli naive bayes
MNLR	Çok terimli lojistik regresyon
MrRTF	Çok çözünürlüklü sırt üstü düzlük indeksi
MrVBF	Çok çözünürlüklü vadi dibi düzlük indeksi
MSAVI	Modifiye toprak ayarlı bitki indeksi
MSI	Multispektral
NDSI	Normalize fark tuzluluk indeksi
NDVI	Normalize fark bitki indeksi
Nm	Nanometre
NRCS	Doğal Kaynakları Koruma Hizmeti
OIF	Optimum indeks faktörü
PCA	Temel bileşen analizi
R ²	Belirleme katsayısı
RF	Rastgele orman
RMSE	Kök ortalama kare hatası
RVI	Bitki oran indeksi
SAVI	Toprak ayarlı bitki indeksi
SPI	Akış gücü indeksi
STH	Sayısal toprak haritalama
SVM	Destek vektör makinesi
SYM	Sayısal yükseklik modeli
SYSI	Sentetik toprak görüntüsü

TOA	Atmosfer üstü yansıma
TWI	Topoğrafik ıslaklık indeksi
USDA	Amerika Birleşik Devletleri Tarım Bakanlığı
UTM	Evrensel enlem merkatörü
WRB	Dünya toprak kaynakları referans sistemi
YKÖ	Yakın kızılötesi
YSA	Yapay sinir ağları
μm	Mikrometre



1. GİRİŞ

Toprak, ekosistemin temel unsurlarından biridir. Tarımsal üretim, karbon tutumu, biyoçeşitliliğinin korunması ve sosyal-kültürel faktörler üzerine etkilidir. Günümüzün stratejik gereksinimleri olan sürdürülebilir gıda üretimi ve iklim değişikliğine adaptasyon çalışmaları için toprak ve su kaynaklarının yönetimi ve planlanması tarımda öncelikli konuların içinde yer almaktadır. Bu yeni koşulların gereksinimlerini karşılayabilmek için ise güncel toprak bilgilerine acil olarak ulaşma zorunluluğu ortaya çıkmıştır.

Geleneksel olarak toprak etüt ve haritalama, saha tanımı, laboratuvar analizi ve ardından sınıflandırma ve haritalama olmak üzere belirli aşamalardan oluşmaktadır. Toprak etütleri ile toprak bilimciler, arazideki konumları, profil özellikleri, birbirleriyle ilişkileri, farklı kullanımlara uygunlukları ve belirli yönetim türlerine yönelik ihtiyaçlar açısından bir alanda var olan farklı toprak türlerini tanımlar. Toprak etüdünün nihai ürünleri, toprak haritalama birimlerinin veya serilerinin raporlarını ve yorumlarını içeren toprak haritalarıdır. Toprak etüt haritalama sonucu üretilen toprak haritaları, çeşitli arazi planları ve yönetim faaliyetleri için toprak özelliklerinin mekânsal dağılımı hakkında önemli bir bilgi kaynağını oluşturmaktadır.

Geleneksel toprak etütlerinde, arazi şekilleri manuel olarak tanımlanır ve toprak, bir toprak araştırmacısının kavramsal modeline göre haritalanır. Bu, çalışılan arazi hakkında çok iyi bilgi gerektiren öznel bir süreçtir. Bu nedenle haritalar, öznel doğası sebebi ile pratik olarak tekrarlanamayan, bireysel toprak etütçüler tarafından geliştirilen zihinsel pedolojik modellerin ürünü olmaktadır.

Bilgi işlem ve bilişim teknolojilerindeki büyük gelişim ile birlikte, tüm çalışma alanlarında çok miktarda veri ve araç ortaya çıkmıştır. Toprak etüt ve haritalama bilimi de bu verilerin kullanıldığı geleneksel öznel varsayımından doğruluk ve belirsizlik konularını da içeren daha nicel modellemeye doğru yönelmiştir.

Sayısal toprak haritalama (STH), geleneksel toprak haritalamanın bazı tutarsızlıklarının giderilmesi bakımından büyük yenilikler sunmaktadır. Sayısal toprak haritalama, mevcut toprak özellikleri ile kapsamlı olarak temin edilebilen yardımcı

veriler arasındaki ilişkileri değerlendirerek, bilgisayar destekli toprak haritalarının üretimine dayanır.

Sayısal toprak haritalama (STH)'nın metodolojisi, alan temelli morfolojik gözlemleri ve laboratuvar ölçümlerini, toprak oluşum faktörlerini temsil eden çeşitli zengin raster tabanlı jeo-uzamsal çevresel veri kaynakları ile entegre edebilmesi olarak tanımlanabilir. Bu süreç, çevresel değişkenleri herhangi bir toprak bilgisiyle ilişkilendiren matematiksel veya istatistiksel modellerle piksel tabanlı toprak haritalarının oluşturulmasıyla etkinleştirilir.

Sayısal toprak haritalama (STH), birkaç on yıl önceki bilim odaklı bir araştırma aşamasından şu anda tamamen işlevsel bir sürece dönüşmektedir. Bu gelişim, sayısal toprak haritalama (STH) projelerinin küçük araştırma alanlarından bölgesel, ulusal ve hatta kıtasal alanlara doğru artan kapsamıyla ortaya konmaktadır.

Matematik ve istatistik bilimlerindeki son gelişmeler, bu bilimlerin toprak bilimi çalışmalarında uygulanmasına yol açmıştır. Toprağın belirli işlevleri yerine getirme yeteneğini göstermek için sayısal toprak haritaları kullanılabilir. Sayısal toprak haritalama (STH) tekniği, kantitatif toprak-arazi modellerine dayalı olarak toprak özelliklerinin ve toprak sınıflarının tahmin edilmesiyle buna yönelik çözümler sunmaktadır.

Tüm ülkeyi haritalamak için, geleneksel yöntemler maliyetli ve zaman alıcıdır. Sayısal toprak haritalama (STH), maliyette sağlayabileceği kolaylık ve doğruluk ile toprak bilgilerini tahmin etmek ve toprak haritalarını üretmek, acil ihtiyaçların karşılanması adına bir alternatif olabilecektir. Ülkelerin kabul görmüş sınıflandırma sistemleri göz önünde bulundurularak öznel toprak haritalarının hazırlanmasını hızlandırarak günümüz veri akış hızına ayak uydurmayı sağlayabilecektir.

Geleneksel toprak haritalamada bahsedilen sınırlamalar ve eksikliklerle ilgili olarak ve Sayısal toprak haritalamanın Dünyada işlevsel toprak harita üretme potansiyeli göz önünde bulundurularak bu tez çalışması yapılmıştır. Çalışmada Amerikan Toprak Sınıflama Sisteminde Ordo seviyesinden Seri seviyesine (USDA-Soil Taxonomy, 1999), FAO/UNESCO (FAO, 1998) sınıflandırma sisteminde Referans Toprak

Grupları ikinci seviyesinde Sayısal Toprak Haritalama metodolojisinin kullanımı amaçlamıştır. Çalışmanın başarısı üretilen sınıf ve sınırların yersel doğrulukları ile karşılaştırılması neticesinde ortaya konulmuş ve literatürde benzer alanlardaki çalışmalarla karşılaştırılmış ve tartışılmıştır.

Çalışmada özellikle kategorik toprak sınıflarının haritalanması, genel sınıflandırma alanına giren bir karar verme süreci olarak göz önüne alındığı için, makine öğrenme alanında sınıflandırma için geliştirilen algoritmaların kullanılabilirliği araştırılmıştır.



2. KAYNAK ÖZETLERİ

2.1. Geleneksel Toprak Haritalama Çalışmaları

Topraklar çevreleriyle birlikte gelişir ve doğal arazinin önemli oranda işlevsel bölümünü temsil eder. İyi bir toprak etütçüsü, araziye özelliklerine göre anlayabilir ve topraklar ile çevresinin genel veya belirli özellikleri arasındaki ilişkileri belirleyebilir. Deneyimli bir etütçü, arazi şekli, jeomorfoloji, bitki örtüsü, jeoloji gibi arazi özelliklerini gözlemler ve daha sonra bu bilgiyi toprak değişkenlerini tahmin etmek ve alandaki homojen toprak birimlerini tanımlamak için kullanır (Dobos ve Hengl, 2009).

Geleneksel toprak haritalama işleyişinde, hava fotoğrafları ve 1:25 000 ölçekli topoğrafik haritalarla birlikte güncel açık erişim sağlayan hizmetler (Google earth vb.) en önemli kartografik materyalleri oluşturmaktadır. Bu materyaller, toprak profillerinin ve morfolojik gözlemlerin tanımlanacağı yerlerin saptanması ve olası toprak sınırlarının çizilmesi amacıyla arazi çalışmaları için ön büro çalışmalarında hazırlanır. Özellikle toprak profillerinin ve morfolojik gözlemlerin tanımlanacağı yerler, jeolojik, jeomorfolojik ve topoğrafik bilgilerin de yardımıyla kartografik materyaller üzerinde belirlenmektedir. Haritalanacak toprak seviyelerinin tanımlanıp örneklenmesi ve toprak haritalama lejantının oluşturulması aşamalarından sonra, etüt-haritalama konusunda bilgi birikimi ve tecrübesi olan etütçüler tarafından arazi çalışması gerçekleştirilir. Bu çalışmalar sırasında belirlenen farklı toprakların sınırları ve bu sınırların arazideki dağılımları toprak etütçüleri tarafından belirlenir ve mevcut kartografik materyal üzerine çizilir.

Geleneksel toprak haritalamada arazi gözlemlerinin en önemlisi profil tanımlamalarıdır. Bununla birlikte, arazi birimlerini temsil eden profillerin sayısı ölçeğe bağlıdır. Daha büyük ölçekte toprak değişkenliğini tanımlamak için daha fazla gözlem gerekmektedir. Bir gözlem, 1: 2000 ölçeğinde 1 ila 4 hektarlık, 1: 10000 için 10–25 hektar ve 1: 25000 ölçek için 25–80 hektarlık bir alanı karakterize edebilir (Hengl, 2006). Arazide morfolojik olarak tanımlanan toprak profili pedon adı verilen en küçük toprak birimini temsil eder. Pedon, horizon şekillerinin ve ilişkilerinin tam olarak çalışılmasına izin verecek kadar büyük yatay boyutlara sahip üç boyutlu bir

toprak gövdesidir ve genellikle alan olarak 1 ila 10 m² arasında değişir (Soil Survey Division Staff, 2017).

Pedonların gruplandırılması ile bir toprak tanımlamasına gidilir. Pratik olarak arazi üzerine çizilmiş ve aynı tip toprakla bir alanı temsil eden haritalama üniteleri oluşturularak haritalama süreçleri gerçekleştirilir. Geleneksel toprak haritalamada haritalama ünitesi tabanlı yaklaşımı, haritalama ünitelerinin aralarındaki sınırın ani değişimi temsil edebilmesi ile haritalama ünitesi içerisinde kalan alanların nispeten homojen olduğunu varsaymaktadır.

Haritalamanın kapsamı, toprak oluşturma süreçlerine ve morfolojik özelliklere dayanan bir morfo-genetik yaklaşımdır ve Dokuchaev ve Jenny'nin (1941) fikirlerine dayanmaktadır. Toprak sınıflandırması, nem rejimi, teşhis edici horizonlar ve pedojenetik süreçlerle ilgili hiyerarşik bir sisteme dayanmaktadır.

Uluslararası literatürlerde, toprak etüt ve haritalama çalışmalarında yenilikçi teknolojilerin kullanımı 1970'li yıllarda Landsat serisinin uzaya gönderilmesi ile başlamıştır. Weismiller (1977), Missouri'deki toprakların envanterini oluşturmak için Landsat uydusuna ait uydu görüntülerini ve topoğrafik verileri kullanmıştır. Franklin (1987), Landsat MSS verilerini arazi birimleri sınıflarının sınıflandırılması için SYM'den türetilmiş arazi tanımlayıcı katmanlarıyla kullandığında, sınıflandırma doğruluğunun %46 ila %75 oranında arttığını bildirmiştir.

Sarabchi vd. (2008), İran'da yaklaşık 1300 hektarlık bir alanı kaplayan çalışma alanında, toprak haritalamada Landsat ETM+ verilerini kullanma potansiyelini değerlendirmek amacıyla yürüttükleri çalışmada, optimum indeks faktörü (OIF) ve temel bileşen analizi (PCA) kullanılarak en iyi bilgilendirici bantların seçimini gerçekleştirmişler, TM1, TM4 ve TM6-2 bantlarının en yüksek bilgiyi içerdiğini belirlemişlerdir. Bitki örtüsü olmayan veya seyrek olan kurak, yarı kurak topraklarda toprak haritalama birimlerinin üretilmesi için Landsat ETM + verilerinin yüksek potansiyele sahip olduğunu bildirmişlerdir.

Türkiye'de toprak sınıflandırma ve haritalama ile ilgili başlangıç düzeyinde çalışmalar Çağlar (1951), tarafından yapılmış ve toprakların morfolojik özellikleri göz önünde

bulundurularak oluşturulan Türkiye toprak haritasında 11 farklı toprak grubu yer almıştır (Dinç vd., 1987). İlerleyen süreçte (Oakes, 1954), yaptığı arazi çalışmaları sonucunda 1938 Amerikan Toprak Sınıflandırma Sistemi'ndeki en son güncellemelerde dikkate alınarak büyük toprak gruplarının yanı sıra eğim, taşlılık, drenaj ve tuzluluk gibi toprak fazlarını da esas alarak 1:800000 ölçekli Türkiye Umumi Toprak Haritasını hazırlamıştır. Topraksu Genel Müdürlüğü tarafından 1966-1971 yılları arasında “Türkiye Geliştirilmiş Toprak Haritası Etüdleri” çalışması ile ülke toprakları 1:25000 ölçekli topoğrafik haritalar temel alınarak yoklama (istikşafi) düzeyde incelenerek haritalanmıştır. Bu çalışmada haritalama ünitesi olarak “1938 Amerikan Sınıflama Sisteminin” büyük grupları ile arazi gözlemleriyle saptanan bunların önemli fazları derinlik, eğim, taşlılık, erozyon ve benzer özellikler haritalara işlenmiştir. Elde edilen veriler değerlendirilerek her bir il için 1:100000 ölçekli “Toprak Kaynağı Envanter Haritası ve Raporu” ve ülkemizde mevcut 26 büyük su toplama havzası için 1:200000 ölçekli “Havza Toprak Haritası ve Raporu” şeklinde yayınlanmıştır. Yapılan çalışma yarı detaylı olduğundan 1:25000 ölçeğin imkân tanıdığı bütün ayrıntılara inilememiştir (Özcan vd., 2004).

Bilimsel ve teknolojik ilerlemeler neticesinde ortaya çıkan veri kaynakları ve yöntemler geleneksel toprak etüt haritalama çalışmalarının gelişmesine olanak sağlamıştır. Coğrafi bilgi sistemleri, uzaktan algılama ve küresel konumlandırma sistemlerindeki gelişmelerle birlikte bu teknolojiler geleneksel toprak etüt ve haritalama çalışmalarında büro ve arazi süreçlerinde kolaylıklar sağlamıştır.

Coğrafi bilgi sistemleri (CBS), küresel konumlandırma sistemleri (GPS), uzaktan algılanan spektral veriler, sayısal yükseklik modellerinden (SYM) elde edilen topoğrafik veriler, veri analizi yazılımlarının kullanılabilirliği ile oluşturulan tahmin veya çıkarım modelleri, toprak etüt biliminin ilerlemesine büyük katkıda bulunmuştur. Günümüzde Geleneksel toprak haritalama, GPS aracılığı ile coğrafi olarak referans alınan alandaki gözlemleri ve CBS'de görselleştirilen dijital yükseklik modellerini içerebilmektedir (Brown vd., 2017).

Gelişen teknolojilerin Türkiye’de uygulama yıllarının başlangıcı uluslararası literatürü takip etmektedir. Dinç vd., (1987) Landsat TM verilerini kullanarak Güneydoğu Anadolu bölgesinde yaptıkları toprak etüt ve haritalama çalışmasında kartoğrafik

materyal olarak kullanmışlar ve etkinliğini bildirmişlerdir. Etkinlik olarak Landsat-TM uydu verilerini kullanarak toprak haritalarının daha ekonomik ve daha hızlı bir şekilde tamamlanabileceğini bildirmişlerdir. Sarı (1987), yılında yaptığı çalışmada Landsat 4 uydu görüntüsünün toprak serilerinin ayırımında kullanılmasının iyi derecede sonuçlar verdiğinin bildirmiştir. Başayığit vd. (1998), Adıyaman-Kahta Sulama sahası proje alanının detaylı toprak etüt haritalama çalışmalarında Landsat TM 3-5-7 bant kombinasyonunu kullanarak gerçekleştirdiği çalışmada, sonuçların yersel arazi doğrulamalarıyla %90 oranında uyum gösterdiğini bildirmiştir.

Başayığit ve Dinç (2001), toprak etüt ve haritalama çalışmalarında bilgisayar teknolojilerinin kullanımını özetlediği çalışmada, en geleneksel haritalama metotları ile karşılaştırıldığında arazi çalışmaları için harcanan sürenin %80 azaltıldığını, doğruluğun ise %90'ın üzerinde olduğunu bildirmiştir.

Özelikle 2000'li yılların başlangıcı ile birlikte Landsat uydusunun sağladığı 30 m yersel çözünürlük ve uluslararası erişime kolaylık sağlama politikaları neticesinde verilere ulaşmanın verdiği kolaylıkla uydu görüntüleri toprak etüt ve haritalamanın ayrılmaz bir parçası olmuştur.

Türkiye'de bu süreçte birçok yüksek lisans ve doktora çalışmasında bu veri kaynakları kullanılmış ve sonuçları tartışılmıştır.

Atatanır (2004), IKONOS sayısal uydu verilerinin detaylı toprak haritalarının hazırlanmasında kullanılma olanaklarının Ege bölgesinde seçilen örnek bir alanda araştırılması üzerine yaptığı çalışmada toprakların değişim gösteren özelliklerinin en iyi belirlenebileceği bant kombinasyonları olarak Landsat 7 ETM + için 3 5 ve 7. bantlar, IKONOS uydu görüntüsü için ise 1. 2. ve 3. bantlar olduğunu belirlemiştir.

Aksoy vd. (2009), engebeli bir arazide toprak etüdü için bir ön harita olarak eğim sınıfı haritasının renkli kompozit görüntülerin kullanımı test etmek amacıyla yaptıkları çalışmada veri katmanları olarak, Landsat uydu görüntülerinden ve 10 m SYM'den elde edilen verilerini kullanmışlardır. İki farklı fizyografik birim üzerinde oluşan altı toprak serisi belirlenmiş, toprak profilleri toprak taksonomisine ve dünya referans

sınıflandırma (WRB) sistemine göre sınıflandırılmıştır. Metodolojinin, toprak etüdü ve bazı toprak türlerinin haritalanması için yeterli olduğunu bildirmişlerdir.

Solmaz (2010), Eğimli arazilerin detaylı toprak etüt ve haritalanması için uzaktan algılama ve coğrafi bilgi sistemleri teknolojilerini kullanarak yeni yöntemlerin geliştirilmesi amacıyla yürüttüğü çalışmada, yapay sinir ağları, toprak fizyoğrafya etkileşim modeli (SoLIM) ve görüntü sınıflama teknikleri kullanılarak bir toprak etüt ve haritalama çalışmasının her aşaması için süre ve maliyeti azaltıcı yöntemler üzerine araştırmalar yapmış, sayısal haritalama teknikleriyle toprak sınırlarının arazi öncesi tahmin edilmesinde hedeflenen performansa ulaşamadığını bildirmiştir. Bunun sebebinin özellikle çalışma alanının, toprakların dağılımı yönünden çok heterojen olması ve veri kaynaklarının yetersizliği olduğunu bildirmiştir.

Dedeoğlu (2017), K.O.P. Beşgözler proje alanı topraklarında yürüttüğü çalışmada yersel çözünürlüğü göreceli olarak yüksek olan Quickbird uydu görüntüsünü doğal drenaj desenleri, fizyoğrafik üniteler ve arazi şekillerinin çıkartılmasında etkin olarak kullanmıştır.

Esetlili vd. (2020), stereo ortamda toprak haritasında yorum yapma çalışmalarında çok bantlı yüksek çözünürlüklü uydu görüntülerinin sağladığı faydaları belirlemeye yönelik yaptığı çalışmada, stereo hava fotoğrafları ile WW-2 uydu görüntülerinden sağlanan kızılötesi başta olmak üzere çok bantlı veriler “Fusion” tekniği ile birleştirilmesi neticesinde elde ettikleri yeni görüntülerle stereo ortamda fizyoğrafya-yansıtma karakteristiklerinin birlikte değerlendirilerek seri düzeyinde toprak haritalarının daha yüksek bir doğruluk oranı ile yapılmasında başarılı olacağını belirlemişlerdir.

Geleneksel toprak haritalamada yenilikçi teknolojilerin kullanılması ile bir kısım ilerlemeler olsa bile, haritalama üniteleri şeklinde gruplandırılmış toprak haritalarının kalitesi ve kullanışsızlığı uzun yıllardır tartışma konusu olmaya devam etmektedir. Son 30 yıldaki teknolojik ve kuramsal gelişmeler, toprak haritalama alanındaki birçok yeni metodolojik ilerlemeye öncüllük etmiştir (Aksoy, 2011).

Geleneksel toprak haritaları, toprak haritası birimlerinin birden fazla toprak-çevresel değişkenle kesiştiği ve örneklenmemiş yerlerdeki toprakları tahmin etmek için kullanılabildiği makine öğrenme araçları için eğitim verisi kaynağı olarak büyük bir değere sahiptir.

Sayısal toprak haritalamanın, bir coğrafi veri tabanında (raster), toprak sınıflarının veya toprak özelliklerinin tahminlerini oluşturmak için niceliksel çıkarım modellerini kullanması ön plandadır. Veri madenciliği, istatistiksel analizler ve makine öğrenimine dayalı modeller, mekânsal desenler için çok büyük miktarda coğrafi veriyi anlamlı kümelerle ayırabilmektedir. Arazi desenlerinin birden çok mekânsal ölçekte hızlı görselleştirilmesini ve belirlenebilirliğini kolaylaştırmak için uluslararası çeşitli sayısal toprak haritalama araçları, metodolojileri ve çıkarım modelleri geliştirilmiş ve test edilmiştir (Lagacherie vd., 2007; Hartemink vd., 2008; Behrens vd., 2010; Minasny vd., 2012).

Bu kapsamda Sayısal toprak haritalama ayrı bir başlık altında sunulabilecektir.

2.2. Sayısal Toprak Haritalama Çalışmaları

Sayısal toprak haritası, her pikselin belirli bir coğrafi konuma sahip olduğu ve toprak verileri içerdiği bir ızgara şeklinde düzenlenmiş 2 boyutlu hücrelerden (piksel) oluşan bir rasterdir. Sayısal toprak haritalamanın önemli bir bileşeni toprak gözlemleri ve çevresel değişkenler arasındaki ilişkiyi tanımlamak için kullanılan analiz yöntemidir (Brown vd., 2017). Analiz yöntemleri, klasik istatistiksel yöntemler, jeostatistiksel yaklaşımlar ve hibrit yöntemler gibi üç ana kategoriye ayrılabilir (McBratney vd., 2003).

Sayısal Toprak haritalama, toprakla ilgili girdi (alan) verilerine ve toprak oluşumunun gerçekleştiği ortamı karakterize eden ortak değişkenlere ihtiyaç duyar.

Sayısal Toprak haritalama, bilinen yerlerdeki arazi örneklerinin mevcut veri tabanları ile birlikte toprak bilgisine katkıda bulunan toprak niteliklerinin (özelliklerinin) mekânsal bir veri tabanını oluşturur. Toprak veri tabanı oluşturmaya ek olarak, sayısal

toprak haritaları aynı zamanda mekânsal tahminlerle ilişkili belirsizlikleri de açıklamaktadır.

Dijital çevresel değişkenler tarafından temsil edilen arazinin değişkenliğini istatistiksel olarak yakalamak için nesnel örnekleme planları uygulanabilir. Sayısal toprak haritalamanın en dikkat çekici yönü, toprak sınıfları veya özelliklerini ve bununla ilgili belirsizlikleri mekânsal olarak üretebilme yeteneğidir. Burada belirsizliğin tanımı, belirli bir toprak tipi veya toprak özelliğinin Dünya yüzeyinde belirli bir noktada meydana gelme olasılığını bilinen hata oranları ile belirleyebilmektir (Brown vd., 2017).

Sayısal toprak haritalama da en önemli bölümlerden bir tanesi, Jeny (1941)'nin belirttiği toprak oluşum faktörlerinin dijital olarak hangi veriler ile temsil edileceğinin belirlenmesi sürecidir. Buna yönelik Sayısal toprak haritalama literatürü zengin bir içerik barındırmaktadır. Genel anlamda 5 faktörle ilgili, ayrı başlıklar halinde Sayısal toprak haritalamada kullanılan çevresel değişkenlerden örnek çalışmalar verilerek bahsedilecektir.

2.3. Sayısal Toprak Haritalamada Kullanılan Çeşitli Çevresel Değişkenler

Sayısal toprak haritalama çalışmasında ilgilenilen alandaki toprak gelişimi ve dağılımı için hangi çevresel değişkenlerin en önemli olduğunu belirleme aşaması önemlidir. Bunlar belirlendikten sonra, söz konusu fiziksel alanların ayrımını sağlamak için ilgili spesifik arazi ve spektral özellikler tanımlanabilir ve uygun dijital veriler seçilebilir.

Sayısal toprak haritalama çalışmalarında toprak kategorik düzeylerinin veya toprak özelliklerinin mekansal tahmininde ilk adım, belirli bir arazide farklı toprakların oluşumunu etkileyen bir dizi öngörücü çevresel değişkenleri belirlemek ve bir araya getirmektir. Farklı arazilerde, farklı toprak oluşturan faktörlerin değişen derecelerde etkisi nedeniyle dahil edilecek kesin çevresel değişkenler dizisi yoktur (Zhu vd., 2001).

Toprak haritalamanın bilimsel temeli, Jenny 'nin (1941) yeryüzündeki toprakların (S) beş işlevde oluştuğunu gösteren kavramsal modeline dayanmaktadır.

Çevresel faktörler, İklim (cl), organizmalar (o), topoğrafya (r), ana materyal (p) ve zaman (t):

$$S = f (cl, o, r, p, t).$$

CLORPT olarak da bilinen bu model, geleneksel toprak haritalamada faydalı olmasına rağmen, niceliksel veya mekânsal olarak belirgin özelliklere sahip değildir. Toprağı ve ilgili çevresel faktörleri mekânsal bir bağlamda temsil etmek ve bu ilişkileri nicel olarak ifade edebilmek amacıyla, McBratney vd. (2003), SCORPAN modelini önermişlerdir. Bu modelde toprak (Toprak sınıfları (Sc) veya Toprak özellikleri (Sa) mekân ve zamandaki bir noktada yedi çevresel değişkenin ampirik nicel bir işlevi) şu şekilde tanımlanmaktadır: Toprak (s), iklim (c), organizmalar (o), topoğrafya (r), ana materyal (p), zaman (a) ve mekânsal konum (n), belirsizlik veya hata (ϵ).

$$Sc, Sa = f (s, c, o, r, p, a, n) + \epsilon$$

SCORPAN modelinde, nokta gözlem verileri, mevcut toprak haritaları veya uzaktan algılanan spektral özellikler girdi verileri olarak kullanılmaktadır. Bu fonksiyonun değişkenleri olarak her bir toprak oluşum faktörü çevresel değişken çerçevesinde değerlendirilecek ve açıklanacaktır.

2.3.1. Toprak

Modelde Toprak, birkaç farklı şekilde türetilen değişkenler ile temsil edilebilir:

- (1) saha veya laboratuvar ölçümlerini temsil eden coğrafi referanslı veriler,
- (2) uzaktan algılanan spektral veriler veya
- (3) mevcut toprak haritalarını içerir.

Toprak verileri, toprak taksonomik sınıfı, ana kayaya kadar toprak derinliği veya genetik horizona göre toprak kimyasal veya fiziksel özellikleri gibi nokta verilerini içerebilir. Toprağın yüzey veya yüzeye yakın özellikleri, uzaktan algılama verileriyle ayırt edilebilen tanısal spektral imzalara sahip olması, uydu görüntülerinden elde edilen bant oranlarının ve indekslerin etkin şekilde kullanımına olanak sağlamaktadır.

McBratney vd. (2003), incelenen alıřmaların yaklaşık %40'ında toprak bilgilerinin kullanıldığını bildirmişlerdir. Özellikle sınıflandırma süreçlerinde geleneksel toprak etüdü verileri, genellikle modelleri eğitmek veya veri tabanı oluşturmak için kullanılır. Toprak haritaları şeklinde mevcut toprak sınıfı verileri, özellikle toprak etüdü güncelleme projelerinde veya toprak haritalama birimlerinin toprak bileşenlerine ayrıştırılmasında da yararlı olabilir (Nauman ve Thompson, 2014).

Mulder vd. (2011a; 2011b), uzaktan algılanan verilerin toprak mineralojisini, toprak dokusunu, toprak nemini, organik karbonu, demir, karbonat içeriğini ve ıplak topraktaki tuzluluğunu haritalamak için yararlı olduğunu belirtmektedir. Uydu görüntülerinin geniş kapsamı ve kullanılabilirliği, ek olarak spektral arşivlerin genişleyen boyutu göz önüne alındığında yalnızca uzaktan algılanan verileri kullanarak toprakların haritalanması ve spektral verilerin daha fazla kullanılması beklenmektedir. Bununla birlikte, atmosferik etkiler ve spektral ve mekânsal çözünürlük ile ilgili gelişen faktörlerde bu duruma eşlik edecektir.

Nield vd. (2007), iki kısa dalga-kızılötesi (SWIR) bandının (5 ve 7 bantları) normalleştirilmiş bir fark oranı ile yüzeysel jips birikimleri ile oluşmuş toprakları dijital olarak haritalandırmak için Landsat 7 ETM + verilerini kullanmıştır.


Landsat 7 ETM + uydusuna ait termal ve yakın kızılötesi bantları ve farklı indisler kullanılarak histosoller belirlenebilmiştir (Başayığit vd., 2017).

2.3.2. Organizmalar

Organizmalar genel olarak bitki örtüsü kavramı ile sayısal toprak haritalama alıřmalarında kullanılmaktadır. Mevcut arazi örtüsü verileri ve uzaktan algılanan spektral veriler dâhil olmak üzere dijital bitki örtüsü veya arazi örtüsü verileriyle temsil edilir. Bitki örtüsü genel olarak uzaktan algılanan spektral verilerle temsil edilir, ünkü yeşil bitki örtüsü yakın kızıl ötesi ışınları (NIR) yansıtmakta ve kırmızı elektromanyetik radyasyonu absorbe etmektedir (Şekil 2.1).

Uzaktan algılama kaynaklarından türetilen spektral veriler dikkate alındığında, spektral çözünürlük en önemli özelliklerden biridir. Spektral çözünürlük, bir sensörün

sağladığı bantlarının sayısını ve yakaladıkları elektromanyetik spektrumun hangi kısmını ifade ettiklerini belirtir. Genel olarak, odak noktamız bitki örtüsü ise spektrumun yakın kızılötesi ve kırmızı kısmı; eğer mineraller, ana materyal veya çıplak toprak ise kısa dalga kızılötesi kısmı önemlidir (Brown vd., 2017).



Şekil 2.1. Spektral ve mekansal çözünürlük

Birçok çalışmada bitki örtüsü varlığı veya yokluğunun derecesi normalize fark bitki indeksi (NDVI) ile tanımlanmaktadır. Multispektral bir görüntünün yakın kızılötesi ve kırmızı bantlarının normleştirilmiş fark oranını ifade eden bu indis, değerleri -1,0 ile 1,0 arasında değişmekle birlikte, yüksek değerler daha yüksek bitki örtüsü yoğunluğunu göstermektedir (Tucker, 1979). NDVI, Landsat verileri gibi yakın kızılötesi ve kırmızı bantları içeren herhangi bir spektral veri kaynağı için ölçülebilir. NDVI, Wyoming'deki Powder River havzasında çok düşük bitki örtüsü bulunan çorak toprak oluşumunu dijital olarak haritalamada önemli bir ortak değişken olarak kullanılmıştır (Cole ve Boettinger, 2007).

Grinand vd. (2008), Fransa'nın batısında 90000 ha alan kaplayan çalışma bölgesinde, 1:100000 ölçekli mevcut toprak haritasını güncelleştirmek amaçlı yaptıkları çalışmada normalize fark bitki indeksini (Tucker, 1979) bitki örtüsü faktörü olarak kullanmışlardır.

Boettinger vd. (2008), Landsat uydusunun spektral verilerinin, özellikle kurak ve yarı kurak alanlarda, arazideki toprak dağılımını dijital olarak haritalamak için yararlı çevresel değişkenleri temsil ettiğini bildirmişlerdir. Eşsiz toprakların benzersiz toprak oluşturan faktör kümelerinin ürünleri olduğu ortak kavramsal modeline dayanarak, Landsat spektral verilerinin bitki örtüsü (örneğin normalize fark bitki indeksi, fraksiyonel bitki örtüsü), ana materyal ve toprak (örneğin, jipsli ve kalkerli malzemeler için tanimsal bant oranları) için kullanılabileceğini bildirmişlerdir. Sayısal yükseklik modellerinden (SYM) elde edilen topoğrafik verilerin (örn. eğim, bileşik topoğrafik indeksi), arazideki toprak dağılımını nicel olarak modellemek için Landsat uydusundan türetilen verilerle birleştirmenin daha etkin sonuçlar vereceğini ifade etmişlerdir (Boettinger, 2010).

Heung vd. (2017), British Columbia'nın güneyinde 47 350 km² alanda Landsat uydu verilerinden ürettiği geliştirilmiş bitki örtüsü indeksi (EVI) (Jiang vd., 2008) modifiye toprak ayarlı bitki örtüsü indeksi (MSAVI) (Qi vd., 1994) Normalize fark bitki indeksi (NDVI) (Tucker, 1979) ve toprak ayarlı bitki indeksini (SAVI) bitki örtüsü faktörünü temsil edecek şekilde çevresel değişken olarak kullanmıştır (Huete, 1988).

Zeraatpisheh vd. (2019), İran'ın Borujen bölgesinde 86000 ha alanda toprak sınıflarını tahmin etmeye yönelik yaptıkları çalışmada normalize fark bitki indeksi (NDVI) (Tucker, 1979), bitki oran indeksi (RVI) ve toprak ayarlı bitki örtüsü indeksi (SAVI)'ni bitki örtüsü faktörünü temsil edecek çevresel değişken olarak kullanmışlardır.

Forghani vd. (2020), İran'ın güneydoğusunda yer alan Sistan ve Baluchestan illerinin kuzeyindeki 60000 ha alanda toprak sınıflarını tahmin etmeye yönelik yaptıkları çalışmada, Normalize fark bitki örtüsü indeksi (NDVI) (Tucker, 1979) ve Normalize fark tuzluluk indeksi (NDSI)'ni çevresel değişken olarak kullanmışlardır.

Dünyanın farklı iklim bölgelerinde ve farklı biyo-coğrafya alanlarında uydu verisinden elde edilen örnekleri verilen bitki indisleri kullanılmaktadır.

2.3.3. Ana materyal

Ana materyal için dijital veriler, bir jeoloji haritasından veya ana materyalin mineralojik ilişkilerini ayırt etmek için uzaktan algılanan spektral veriler kullanılarak elde edilebilir. Farklı ana materyallerdeki (kayaçlar ve sedimanlar) mineral topluluklarının spektral tepkilerinde değişiklikler olacaktır. Mineraller, Landsat TM veya 7 ETM 5 ve 7 bantları, Landsat 8 OLI 6 ve 7 bantları ve Gelişmiş Termal Emisyon ve Yansıma Radyometresi (ASTER) 4 ve 9 bantları ile temsil edilen, elektromanyetik spektrumun kısa dalga kıvrım aralığında özellikle duyarlıdır.

Önceki çalışmalarda, toprak renginin mineralojik bileşimin, özellikle demir oksitler ve organik madde içeriğinin bir fonksiyonu olduğunu ortaya koymuştur (Chabrillat vd., 2019; Poppiel vd., 2019).

Marchetti vd. (2011) İtalya'nın Teramo bölgesinde toprak türlerinin uzaktan algılama verileriyle simülasyonu amacıyla yaptığı çalışmada, tahmin edici çevresel değişken olarak ana materyal faktörünü temsil etmek üzere doğrudan uydu görüntüsünün spektral bantlarını kullanmak yerine, toprak yüzeyinde ince kum içeriği ile ilişkili üst toprak tane büyüklük indeksi (GSI) (Xiao vd., 2006) ve kil içeriği ile korelasyonlu olan kil indeksini kullanmışlardır.

Abdel-Kader (2011), Mısır'ın kuzeybatısında 2 farklı bölgede yürüttüğü çalışmada Landsat 7 ETM+ uydusuna ait bantlardan toprak pedojenezi ile ilişkili toprak indekslerini, toprak ana materyal faktörünü temsil edecek çevresel değişken olarak belirlemiştir. Bunlar, üst toprak tane büyüklük indeksi (GSI) (Xiao vd., 2006), karbonat indeksi (CarInd) (Boettinger vd., 2008) ve jips indeksi (Nield vd., 2007)'dir.

Taghizadeh-Mehrjardi vd. (2015), İran'ın kuzeybatısındaki önemli bir tarım bölgesi olan yaklaşık 3000 hektarlık alanda, ana materyali ve toprak faktörleri olarak kil indeksi (Boettinger vd., 2008); B6/B4 oranı (Gad ve Kusky, 2006); karbonat indeksi (Boettinger vd., 2008); jips indeksi (Nield vd., 2007); tuzluluk oranı (Metternicht ve Zinck, 2003) ve parlaklık indeksini (Metternicht ve Zinck, 2003) kullanmışlardır.

Mosleh vd. (2017), İran'ın Chaharmahal-Va-Bakhtiari ilinin Shahrekord ovasında yaptıkları çalışmada, ana materyal faktörünü Landsat uydusundan elde edilen kil ve karbonat indeksini (Boettinger vd., 2008) kullanarak temsil etmişlerdir. Kurak iklim şartlarının hâkim olduğu bölgede, bu indeksler ordo ve alt ordo ayırımında model de önemli değişkenler olarak belirlenmiştir.

Houngpatin vd. (2018), Burkina Faso'nun Güneybatısında 155 km² alanda yürüttükleri çalışmada RapidEye ve Landsat 8 OLI uydularından özellikle tarım alanlarında kurak mevsimin zirvesi olan ve toprakların çoğunlukla çıplak olduğu toprak işleme dönemine karşılık gelen tarihlerde elde ettikleri görüntülerde, ortalama yansıma büyüklüğünü temsil eden parlaklık indeksi, spektral eğimi temsil eden doygunluk indeksi (SI), ana rengi temsil eden ton(hue) indeksi , toprak rengini temsil eden renk indeksi ve hematit içeriğini temsil eden kırmızılık indeksini hesaplamışlar ve toprak ana materyalini temsil edecek çevresel değişken olarak kullanmışlardır.

Poppiel vd. (2019), nem duyarlılığı, bitki artığı ve yanmış alanlardan çıplak toprağı ayırmak amacı ile orta kızılötesi indeks (MIDI)'i geliştirmişlerdir.

Assami ve Aissa (2019), Cezayir'in Zeb-El Gherbi bölgesinde, 22573 ha alanda yürüttükleri çalışmada Landsat 5 TM görüntüsünden ana materyali temsil edecek çevresel değişken olarak bant oranı (Bant 1/Bant 7), Tuzluluk 3 indeksi (Douaoui vd., 2006), üst toprak tane büyüklük indeksi (GSI) (Xiao vd., 2006) ve jips indeksi (Nield vd., 2007)'ni kullanmışlardır.

Demattê vd. (2020), Google Earth Engine (GEE) bulut platformu kullanılarak Landsat 4 TM, Landsat 5 TM, Landsat 7 ETM + ve Landsat 8 OLI görüntüleme alanlarının çıplak toprak yüzeylerinin elde etmek için bir metodoloji geliştirmişlerdir. Sentetik toprak görüntüsü (SYSI) olarak adlandırılan ürün, ana materyal değişkeni üretmek amaçlı metodoloji ürünü olarak kullanılabilecektir.

Toprak ana materyalini ve toprak oluşumunu değerlendirmek için yararlı bir bilgi kaynağı, jeomorfoloji haritalarının kullanımıdır. Scull vd. (2005), kurak bölgelerde toprak sınıflarının mekânsal dağılımını belirlemede jeomorfolojik süreçlerin baskın rolünü göstermiştir.

2.3.4. Topoğrafya

Topoğrafya, arazideki su ve enerjinin dağılımını ve birikimini kontrol eder, bu sebeple toprakları ve toprak özelliklerini etkileyen baskın faktör olarak literatürde yaygın bir şekilde kabul görmüştür. Topoğrafya büyük ölçüde toprak dokusunu, drenaj durumunu ve profil gelişimini belirlemektedir (Macmillan vd., 2004). Yerel arazi biçimini, su ve tortu hareketini kontrol ettiği için topraklar üzerinde büyük bir etkiye sahiptir (McKenzie ve Ryan, 1999).

McBratney vd. (2003), Sayısal toprak haritalama ile ilgili 132 makaleyi gözden geçirmiş ve STH çalışmalarının yaklaşık %80'inin dijital yükseklik modellerini topoğrafya (r) faktörünü temsil etmek için kullandığını bildirmiştir. Sayısal yükseklik modelleri ve ondan hesaplanan diğer arazi türevleri, kolayca elde edilebildikleri ve kapsam açısından tutarlı oldukları için özellikle yararlıdır. Ek olarak, eğim, eğrilik, bakı gibi birçok arazi türevi bir SYM'den hesaplanabilir. Arazi türevleri, toprak oluşumunu etkileyen hidrolojik süreçleri tasvir etmek için kullanılabilir.

Topoğrafyayı temsil eden ortak değişken, Lazer Görüntüleme Tespiti ve Aralığı (LiDAR), uluslararası hava ajanslarınca sağlanan erişime açık sayısal yükseklik modelleri (NASA, 2019), fotogrametrik veriler vb. gibi yükseklik verilerinden elde edilebilir. Bu veriler, arazi özellikleri veya yükseklik türevleri olarak bilinir. Arazi özelliklerinin çeşitli kombinasyonları jeomorfik yüzeyler oluşturabilir ve toprak gelişimi ile ilgili işlemleri tanımlayabilir.

Deniz seviyesinin üzerindeki yükseklik ve eğim yönü, bölgenin yağış ve sıcaklık rejimini değiştirerek iklim etkisini değiştirir. Eğim derecesi, yüzey akışının, erozyonun, çökmenin ve sızmanın yoğunluğunu yönlendirerek çok sayıda toprak özelliğini etkilemektedir. Düz alüviyal bölgelerdeki kot farklılıkları, toprak özelliklerinin gelişmesinde en önemli faktörlerden biri olan yer altı suyu seviyesine olan derinliği tanımlamaktadır. Yüzeyin şekli, dışbükey veya iç bükey yapısı, besin elementlerinin ve fiziksel toprak parçacıklarının yanal taşınmasını tanımlayan yüzey drenaj ağını tanımlamaktadır (McKenzie ve Ryan, 1999). Yukarıda sıralanan bu doğrudan etkiler, diğer dört toprak oluşturan faktör üzerindeki dolaylı etkilerle tamamlanmaktadır. Topoğrafya, makro iklimi değiştirir ve yerel yağış ve sıcaklık

değişiminin çoğunu açıklayabilmektedir. Jeoloji ve jeomorfoloji de topoğrafya ile yakından ilişkilidir. Topoğrafyanın toprak oluşumu üzerindeki doğrudan ve dolaylı etkileri, topoğrafyayı en yüksek tahmin değerine sahip, en tanınmış faktör haline getirmektedir. Alt ordo düzeyinde, en yaygın tanımlayıcılardan biri olan iklimi ve su tablası yüksekliğini etkilediği için topoğrafyanın bir işlevi olan toprak nemi veya ıslaklık durumu önem arz eder.

Bakı, toprak bilimciler ve ekolojistler tarafından, mikro iklim ve mikro iklimin neden olduğu olgularda arazi ölçeğindeki değişim için nicel bir veri olarak yaygın olarak kullanılır.

Beaudette ve O'Geen'de (2009), Mollisollerin mekânsal dağılımını tahmin etmek için yaptığı çalışmada Bakı'nın en önemli çevresel değişkenlerden bir tanesi olduğunu bildirmiştir.

Marchetti vd. (2011), İtalya'nın Teramo bölgesinde toprak türlerinin uzaktan algılama verileriyle simülasyonu amacıyla yaptığı çalışmada, tahmin edici çevresel değişken olarak topoğrafya faktörünü temsil etmek üzere 40 metre yersel çözünürlüğe sahip sayısal yükseklik modelinden, yükseklik, eğim, profil ve planform eğrilikleri, güneş radyasyonu ve topoğrafyadaki ve eğimlerdeki su hareketi ile yüzey toprağının nemliliği ile ilişkili olan topoğrafik ıslaklık indeksini hesaplamıştır.

Jafari vd. (2012), İran'ın güneydoğusundaki Zarand bölgesinde toprak sınıfı haritaları üretmek için yaptıkları çalışmada Aster GDEM verisinden elde ettikleri eğim, ortalama eğrilik, ıslaklık endeksi, plan eğriliği, profil eğriliği, topografik ıslaklık endeksi ve çok çözünürlüklü vadi dibi düzlük endeksi dahil olmak üzere yedi arazi özelliği elde etmişlerdir. Teşhis edici toprak horizonlarının tespiti amacıyla yaptıkları bu çalışmada salic horizonun tespitinde eğrilik parametrelerinin önemli çevresel değişkenler olduğunu belirlemişlerdir.

Subburayalu ve Slater (2013), Ohio'nun güneydoğu kesiminde bulunan Monroe County'de 117419 ha alanda seri düzeyinde toprakların sayısal haritalarını güncellemek amacıyla yaptıkları çalışmada Lazer Görüntüleme Tespiti ve Aralığı

(LiDAR) verisinden 30.48 cm çözünürlükte sayısal yükseklik modelini kullanarak 21 çevresel değişkeni topoğrafya faktörünü temsil etmek amacıyla kullanmışlardır.

Taghizadeh-Mehrjardi vd. (2015), toprak familya sınıfları tahmini için en yararlı çevresel değişkenlerin İran'ın Baneh bölgesinde topoğrafik arazi özellikleri olduğunu bildirmiştir. Bunun yanı sıra, Mosleh vd. (2016), SYM özelliklerinin, toprak varyasyonunu tamamen açıklayamasalar da düz alanlarda bile toprak özelliklerini tahmin etmek için yararlı çevresel değişkenler olduğunu bildirmektedir.

Topoğrafik çevresel değişkenler özellikle arazi kullanımlarındaki farklılığın fazla olduğu ve ürün deseninin yıl içerisinde çok farklılaştığı düz tarım alanlarında yoğun olarak toprak sınıflarının ve toprak özelliklerinin tahmini ve haritalamasında kullanılmaktadır.

Mirakzei vd. (2018), İran'ın doğusunda Sistan bölgesi'nde 60000 ha alanda yaptıkları çalışmada, Aster GDEM veri tabanından temin ettikleri sayısal yükseklik modelinden SAGA yazılımını kullanarak ürettikleri 18 çevresel değişkeni topoğrafya faktörünü temsil etmek amaçlı kullanmışlardır.

Topoğrafik yüzeyin eğriliği çoğunlukla profil eğriliği ve planform eğriliği ile ifade edilir. Profil eğriliği, bir yüzeyin eğim yönündeki eğriliği olarak tanımlanır. Planform eğriliği, eğimin yönüne dik bir yüzeyin eğriliği olarak tanımlanır. Pozitif değerler dışbükey yüzeyle, negatifler içbükey yüzeyle ilgilidir ve sıfıra yakın değerler düz yüzey olarak tanımlanır (Zevenbergen ve Colin, 1987). Profil eğriliği, akışın hızlanmasını ve yavaşlamasını etkiler ve bu nedenle toprak erozyonunu ve birikme modellerini etkilemektedir. Planform eğriliği, akışın yakınsamasını ve ıraksamasını ve dolayısıyla suyun arazi boyunca dağılımını etkiler (Klingseisen vd., 2008). Yer şekillerinin sınıflandırılması için, her iki eğrilik değeri de en yaygın işaretleme kuralına göre, içbükey alanlar (çöküntüler) için negatif değerler ve dışbükey alanlar (tepeler) için pozitif değerler ile kodlanmaktadır (Florinsky, 2016).

Silva vd. (2019), Brezilya'nın güneydoğusundaki Posses havzasında gerçekleştirdikleri çalışmada, topoğrafya faktörünü temsil etmek amacıyla yüksek

özünürlüklü (12.50 m) ALOS-PALSAR sayısal yükseklik modelinden sayısal toprak haritalamada yaygın olarak kullanılan 28 çevresel deęişken üretmişlerdir.

2.3.5. İklim

İklim, sayısal toprak haritalama çalışmalarında çevresel deęişken olarak en az kullanılan parametredir. Özellikle, yerel iklim büyük ölçüde topoğrafyadan etkilenir ve sonuç olarak eğim, yükseklik ve bakı gibi topoğrafik deęişkenler iklim deęişkenleri yerine kullanılabilir (Schaetzl ve Anderson, 2005). İklim katmanları olarak, ortalama yıllık sıcaklık, ortalama yıllık yağış ve evapotranspirasyon kullanılabilir (McBratney vd., 2003).

İklim verileri, nokta verileri veya raster dosyaları olarak mevcut olabilir. Küresel ölçekte 1 km mekânsal çözünürlükte bu tür veri kümelerini barındıran WorldClim (Hijmans vd., 2005) gibi veri kaynakları mevcuttur.

Ballabio vd. (2016), LUCAS veri tabanını kullanarak toprağın üst fiziksel özelliklerini Avrupa ölçeğinde haritalanması amaçlı yaptıkları çalışmada, 1 km² mekânsal çözünürlükte WorldClim veri setinden aylık sıcaklık ortalamaları ve aşırı sıcaklık değerleri ve aylık yağış katmanlarını elde ederek mekânsal haritalama amaçlı modelleme sürecinde kullanmışlardır.

Daha çok bölgesel veya kıtasal çalışmalarda etkin olarak kullanılabilen iklim verileri, yerel çalışmalarda, çalışma alanında birden fazla uzun yıllar veri alabilen meteoroloji istasyonu olması durumunda daha yüksek çözünürlükte interpolasyon yöntemleri ile elde edilebilir.

2.4. Kategorik Toprak Sınıflarının Sayısal Haritalanmasına Yönelik Çalışmalar

Toprak taksonomik sınıflarının mekânsal dağılımını haritalamak, toprak mekânsal varyasyonunu karakterize etmek (Lagacherie, 2005) toprakları etkin kullanabilmek için önemlidir. Toprak sınıflarının sayısal haritalarını üretmek için denetimli, denetimsiz sınıflandırma metotları ve bilgiye dayalı yaklaşımlar kullanılmıştır (MacMillan, 2008).

Sınıflandırma, bazı veri kümeleriyle temsil edilen karmaşık bir sistemi, daha açık hale getirecek şekilde öngörme işlemidir. Veri değerlerinin ve özelliklerinin (n-boyutlu) alandaki dağılımına bağlı olarak piksellerin sınırlı sayıda sınıfa ayrılması işlemi olarak tanımlanabilir. Basitçe söylemek gerekirse, eğer bir piksel bir sınıfı tanımlayan kriterleri sağlıyorsa, piksel o sınıfa atanır. Bu işlem bir sınıflandırma algoritmasına göre yürütülür.

Sayısal toprak haritalama için tahmine dayalı modelleme (genellikle istatistiksel modelleme veya makine öğrenmesi), doğru bir tahmin üretmek için sınıflar ile çevresel değişkenler arasındaki gerçek ilişkiyi gösteren matematiksel bir model geliştirme işlemidir. Çevresel değişkenleri ve uygun bir model veya algoritmayı temsil eden gerekli tahmin verisinin seçilmesini içerir.

Denetimli ve denetimsiz öğrenmeye dair yaklaşımlara örnek çalışmalar başlıklar halinde açıklanabilecektir.

2.4.1. Denetimli öğrenme algoritmaları

Sayısal toprak haritalama çalışmalarında mevcut toprak verilerini kullanarak toprak haritalarının iyileştirilmesi ve mekânsal olarak toprak sınıf haritalarının oluşturulması amacıyla çoğunlukla denetimli sınıflandırma algoritmaları kullanılmaktadır.

Toprak haritalama açısından, sınıflandırma algoritmalarında hedef sınıf, bir toprak haritalama birimi olabileceği gibi, belirli sınıflandırma sistemlerince sınıflandırılmış bir sınıf seviyesi de olabilir. Hedef sınıfları yeterince temsil etmek ve anlamlı bir sınıflandırma üretmek için, toprak gözlemleri veya eğitim verileri dikkatlice seçilmelidir.

Eğitim verilerinden gelen sınıf tanımları, çevresel değişkenleri temsil eden ve özenle seçilmiş tahmin edici verilerle birleştirilir ve uygulanan sınıflandırma algoritması, her bir pikselin ait olduğu sınıfı belirler.

En yaygın kullanılan standart denetimli sınıflandırma yöntemlerinden birisi maksimum olasılık algoritması, olasılığı temel almaktadır. Maksimum olasılık,

aday pikselleri sınıflandırmak için eğitim sınıfı araçlarını ve kovaryans matrislerini kullanır. Sınıfların her birine ait aday piksel olasılığı hesaplanır ve olasılığın en yüksek olduğu sınıf piksele atanır (Brown vd., 2017).

Tez çalışmasında uygulanan modellerden bir tanesi lojistik regresyon modelidir. Bu yöntem ile gerçekleştirilen sayısal toprak haritalama çalışmaları ayrı başlık altında verilecektir.

2.4.1.1. Lojistik regresyon algoriması kullanılarak yapılan sayısal toprak haritalama çalışmaları

Hengl vd. (2007), profil gözlemlerinden toprak kategorik sınıflandırma seviyelerini tahmin etmeye yönelik yaptığı çalışmada, toprak kategorilerini tahmin etmek için ikiden fazla sınıfın olduğu bir durumda, iki terimli lojistik regresyonun bir uzantısı olan çok terimli lojistik regresyonu kullanmıştır. 4250 profilden oluşan İran toprak profili veri tabanını kullandığı çalışmada, hedef değişkenler olarak Dünya referans toprak sistemi temel düzeyi belirlenmiştir. Model doğruluk değerlendirmelerinde, %30'luk profil verisinden oluşan bir test seti belirlenmiş ve kriter olarak kappa istatistiğini kullanmışlardır. Her durumda kappa katsayısının %60' tan küçük olduğu ve bunun, öncelikle örnekleme planı (alan ağırlıklı), toprak sınıflarının zayıf tanımı ve toprakların yüksek değişkenliği ile açıklanabileceğini bildirmişlerdir.

Giasson vd. (2008), Brezilya'da, 1: 30000 ile 1: 50000 arasında değişen ölçeklerde mevcut toprak haritası bulunan 3 bölgede lojistik regresyonu kullanarak haritalama birimlerinin mekânsal tahmininde sayısal yükseklik modelinden üretilen çevresel değişkenleri kullanmışlardır. Referans toprak haritasını doğruluk ölçütü olarak kullandıkları çalışmada, genel doğruluk değerlerinin %61 ile %71 arasında, Kappa katsayılarının ise %36 ile %54 arasında olduğunu belirlemişlerdir. Topoğrafik değişkenlerden yükseklik, eğrilik, akış gücü indeksi (SPI), topoğrafik ıslaklık indeksi (TWI) ve akarsulara olan mesafe değişkenlerinin modele katkısının daha önemli olduğunu bildirmişlerdir.

Howell vd. (2008), yükseklik türevleri, ASTER bantları ve bant oranlarını içeren 46 çevresel değişkeni kullanarak, argilik horizon varlığı -yokluğu, ikincil karbonatların

varlığı-yokluğu, kalsik horizon varlığı-yokluğu, duripan varlığı-yokluğu durumlarını ve tekstür sınıflarını, lojistik regresyon kullanarak tahmin etmişlerdir.

Debella-Gilo ve Etzelmüller (2009), Norveç'in güneydoğusunda, WRB-1998 (FAO, 1998) toprak grupları ve topoğrafik özellikler arasındaki ilişkiyi modellemek için sayısal yükseklik modelini (SYM) ve geleneksel olarak yapılmış toprak haritasından örnek toprak verilerini kullanarak yürüttükleri çalışmada, sınıflandırma algoritması olarak lojistik regresyonu kullanmışlardır. Çalışma alanında bulunan her büyük toprak grubunun oluşma olasılığının mekânsal olarak belirlendiği çalışmada, tahmin doğruluğunun tüm toprak sınıfları için aynı olmadığını ve daha iyi doğruluğa sahip toprakların, en azından kendi çalışma alanlarında topoğrafik özelliklerden oldukça etkilenen topraklar (örn. Cambisol, Albeluvisol ve Luvisol) olduğunu bildirmişlerdir.

Kempen vd. (2009), Eski toprak verilerini kullanarak 1:50000 ölçekli Hollanda toprak haritasını güncellemek amacıyla çok terimli lojistik regresyon yaklaşımını kullanmıştır. Model oluşturma süreci, nihai regresyon modelinin sadece istatistiksel olarak sağlam değil, aynı zamanda pedolojik olarak makul olmasını sağlamak için pedolojik uzman bilgisinin dahil edildiği yöntemde, 10 harita birimi için ayrı modeller oluşturmuştur. Güncellenmiş toprak haritası bağımsız bir veri numunesi ile doğrulanmış ve genel doğruluğu %67 olarak belirlenmiştir.

Abdel-kader (2011), Mısır'ın Kuzeybatı kıyı bölgesinde uzaktan algılama verileri ve sayısal yükseklik modelini kullanarak toprak haritalarının üretimi için çok terimli lojistik regresyon modelini dijital bir toprak haritalama yaklaşımında kullanımını araştırmıştır. Toprak sınıflarının mekânsal dağılımını etkileyen en önemli arazi parametreleri, yükseklik, vadi derinliği, çok çözünürlüklü sırt tepe düzlük indeksi, çoklu çözünürlüklü vadi-taban düzlük indeksi ve SAGA ıslaklık indeksidir. Bununla birlikte, en etkili spektral parametreler, Landsat ETM + uydusunun altı bandının ilk iki ana bileşenidir. Tahmin edilen toprak haritalarının genel doğruluğu %72 ile %74 arasında değişirken, kappa katsayısı %62 ile %64 arasında değişmektedir. Geliştirilen olasılık modelleri, Matrouh ve Alamin'deki arazi çalışması yapılmayan alanlarda 28.5 m * 28.5 m ve 90 m * 90 m piksel çözünürlüklerinde toprak haritalama birimlerinin mekânsal dağılımını tahmin etmek için başarıyla kullanıldığını bildirmişlerdir. Geliştirilen metodolojinin, Mısır'ın ulaşılabilen bölgelerinde yeni genişleme

alanlarının tahsisine ve yönetimine yönelik dijital olarak haritalanmasına katkıda bulunabileceğini bildirmişlerdir.

Marchetti, vd. (2011), Toprak tipi dağılımını, arazi özellikleri (eğim, güneş radyasyonu, NDVI, TWI, vb.) ile mekânsal olarak tahmin etmek ve sayısal haritalarını oluşturmak için çok terimli lojistik regresyon kullanmışlardır. Karşılaştırma sonucu, toprak sınıflarının simüle edilmiş mekânsal dağılımının, pedolojik harita ile tutarlı olduğunu ve yerel morfolojiye daha iyi uyduğunu bildirmişlerdir.

Jafari vd. (2012), İran'ın kurak Zarand bölgesindeki USDA-Büyük toprak gruplarının mekânsal tahminini ve haritasını yapmak amacıyla yürüttükleri çalışmada teşhis horizonlarını ve toprak türlerini tahmin etmek için dolaylı bir yaklaşım olarak ikili lojistik regresyonu ve doğrudan bir yaklaşım olarak çok terimli lojistik regresyon yaklaşımlarını karşılaştırmışlardır. Dolaylı tahminle, ilgili teşhis horizonlarının oluşumu ilk olarak haritalanmış ve ardından, teşhis horizonlarının varlığı veya yokluğu birleştirilerek piksel bazlı bir sınıflandırma için çeşitli haritalar birleştirilerek sonuç haritaları üretilmiştir. Doğrudan tahminde, bağımlı değişken büyük grubun kendisi olduğu için, büyük toprak gruplarının olasılık dağılımı doğrudan tahmin edilmiştir. Öngörücüler arasında jeomorfoloji haritası, doğruluğu artırmaya yardımcı olduğu için sayısal toprak haritalama yaklaşımları için önemli bir araç olarak belirtilmiştir. Güvenilir ve esnek bir yaklaşım olarak, lojistik regresyonun, dijital toprak haritalarını hazırlamak için başarıyla kullanılabileceğini ve doğrudan model yaklaşımının, dolaylı yaklaşımdan önemli ölçüde farklı bir performans gösterdiğini belirtmişlerdir.

Collard vd. (2014), Fransa'nın, Haute-Normandie bölgesinde 1580 km² alanda 1: 250000 ölçeğinde istikşafı toprak haritasını iyileştirmek için sayısal toprak haritalamanın faydasını araştırdıkları çalışmada regresyon tekniklerini kullanarak çok sayıda çevresel eş değişkenden faydalanan toprak sınıfını tahmin etmişlerdir. Çalışma alanında çok az toprak noktası gözlemi mevcut olduğundan, toprak haritasını bir grid(ızgara) üzerinde örnekleme noktaları belirleyerek modelleme çalışması yürütülmüş, sınıflandırma ağacı (CT), çok terimli lojistik regresyon (MNLR) ve rastgele orman (RF) modellerini çalışma alanındaki dokuz toprak sınıfını tahmin etmedeki doğruluğunu karşılaştırmışlardır. Yeni ve orijinal haritalar, tabakalı basit rastgele örnekleme tasarımı ile seçilen 123 lokasyondan alan verileriyle doğrulanmış,

MNLR için, genel doğruluk %66 iken, keşif haritasının genel doğruluğu %56 olarak belirlenmiştir.

Brungard vd. (2015), Üç farklı yarı kurak arazide toprak taksonomisi alt grup seviyesinde toprak sınıflarını tahmin etmek için 11 makine öğrenme (K-en yakın komşular (KNN)-Basit, Doğrusal ayırım analizi (LDA)-Basit, Çok terimli lojistik regresyon (MNLR)-Basit, En yakın küçültülmüş ağırlık merkezleri (NSC)-Orta, Sınıflandırma ağacı (CT)-Orta, Torbalama sınıflandırma ağacı (BCT)-Karmaşık, Rastgele orman (RF)-Karmaşık, Doğrusal destek vektör makineleri (SVML)-Karmaşık, Radyal tabanlı destek vektör makineleri (SVMR)-Karmaşık, Tek gizli katmanlı sinir ağı (NNET)-Karmaşık, Çok katmanlı algılayıcı sinir ağı Kompleksi (MLP)- Karmaşık) algoritmasının performansını değerlendirdiği çalışmada, Karmaşık modellerin basit modellerden daha doğru sonuçlar verdiğini ve doğruluğun, sınıf sayısına ve toprak gözlemlerinin sıklık dağılımına bağlı olduğunu bildirmiştir. Makine öğrenimi modellerinin, az sayıda toprak sınıfı olduğunda, toprak pedon gözlemlerinin frekans dağılımının sınıflar arasında yaklaşık olarak eşit olduğunda en doğru sonuçlar verebileceğini bildirmişlerdir. Nitekim toprağın doğası gereği arazide dağılımı homojen olmayabilir. Bu sebeple modelleme sürecinde veri ön işleme adımıyla sınıfların gözlem sayıları dikkate alınmalıdır.

Taghizadeh-Mehrjardi vd. (2015), İran'ın Baneş bölgesinde USDA toprak sınıflandırma sisteminde aile düzeyinde toprak gruplarının mekânsal dağılımını tahmin etmek için lojistik regresyon (LR), yapay sinir ağı (YSA), destek vektör makinesi (SVM), k-en yakın komşu (KNN), rastgele orman (RF) ve karar ağacı (DT) olmak üzere 6 veri madenciliği sınıflandırıcısını karşılaştırmak amacıyla yaptıkları çalışmada, haritalandırılan 5 toprak ailesi sınıfından en yüksek genel doğruluk %71 ve kappa katsayısı %69 olarak DT ve YSA yöntemi kullanılarak elde edilmiştir.

Pahlavan-Rad vd. (2016), Kuzey İran'daki Golestan eyaletinde 85000 ha alanda sayısal toprak haritalamada çevresel değişken olarak eski toprak haritalarının kullanımına dair yaptıkları çalışmada, basit (çok terimli lojistik regresyon) ve karmaşık (rastgele ormanlar) model kullanarak üç toprak taksonomik seviyesini (Büyük Grup, Alt Grup ve Seri) tahmin etmişlerdir. Mevcut eski toprak haritasını bir ortak değişken olarak dâhil etmenin, eski toprak haritasını hariç tutmaktan daha doğru dijital toprak

haritalarına yol açacağı yönündeki araştırma hipotezinin, genel olarak doğru olduğunu bildirmişler ve eski toprak haritalarının sayısal toprak haritalama da çevresel değişken olarak dahil edilmesinin model doğruluğunu artırdığını ancak eski toprak haritasını içeren ve hariç tutan modeller arasındaki model doğruluk değerlerinde nispeten küçük farklar olduğunu bildirmişlerdir. Nispeten küçük farklılıkların, eski toprak etüdü zamanı ile mevcut toprak örnekleme arasındaki toprak değişikliğine veya büyük ölçekli (1:100000) bir eski toprak haritasının kullanımına atfedilebileceğini bildirmişlerdir. Eski toprak etüdü bilgilerinin sayısal toprak haritalamada çevresel değişken olarak dâhil edilebileceğini, ancak toprak etüdü güncellemesi veya ayrıştırma faaliyetleri için özellikle arazi yönetimi faaliyetlerinin toprak değişikliğine neden olabileceği alanlarda kullanıldığında dikkatli olunması gerektiğini bildirmişlerdir.

Makine öğrenimi, bilgisayar tabanlı istatistiksel modeller kullanılarak büyük veri kümelerindeki kalıpların ortaya çıkarılması için otomatikleştirilmiş bir süreçtir; burada üretilen bir model daha sonra yeni veriler üzerinde tahmin amacıyla kullanılabilir (Murphy 2012). Heung vd. (2016), sayısal toprak haritalamada sınıflandırma amaçlı makine öğrenimi tekniklerini karşılaştırma amaçlı yaptığı çalışmada, eğitim veri setini üretmek için, tek bileşenli haritalama birimleri içinde rastgele noktalar oluşturulmuş ve dijital yükseklik modelleri (SYM), uydu görüntüleri ve iklim modeli çıktılarından üretilen topoğrafik, bitkisel ve iklimsel indeksler ile kesiştirilip veri matrisi oluşturulmuştur. Ortaya çıkan toprak-çevresel ortak değişken matrisi daha sonra çeşitli makine öğrenme algoritmalarını eğitmek için kullanılmış ve örneklenmemiş yerler için tahminler yapılmıştır. Makine öğrenme algoritmalarını eğitmek için kullanılan toprak-çevresel değişken eğitim veri matrisini oluşturmak için, eğitim alanlarından 4 örnekleme yöntemi kullanılmıştır. (1) büyük grup başına eşit sayıda örnek noktası (eşit sınıf örnekleme); (2) haritalama ünitesi başına eşit sayıda numune noktası (haritalama ünitesi tabanlı örnekleme); (3) büyük bir grubun kapsamının alan ağırlıklı bir oranı olarak belirlenen örnek noktalarının sayısı (alan ağırlıklı örnekleme); ve (4) alan ağırlıklı örnekleme yaklaşımına uygulanan rastgele aşırı örnekleme (ROS)'dir. ROS, her sınıf için örnek sayısının eşit olduğu 'dengeli' bir veri kümesi oluşturmak amacıyla kullanılan bir yaklaşımdır. Eşit sınıflı örnekleme (yöntem 1), eğitim noktalarının yinelenmediği bir tür 'rastgele örnekleme' (RUS) iken, ROS, az örneklenen sınıflar için eğitim verisi sayısını çoğunluk sınıfındaki örneklerin sayısına eşit olacak şekilde çoğaltması şeklinde çalışmaktadır. Çok terimli lojistik regresyon için, 1. yöntem ile

elde edilen veri matrisinden üretilen model sonucu Büyük grup için %45, Ordo seviyesi için %58, 2. yöntem ile elde edilen veri matrisinden üretilen model sonucu Büyük grup için %42, Ordo seviyesi için %64, 3. yöntem ile elde edilen veri matrisinden üretilen model sonucu Büyük grup için %64, Ordo seviyesi için %81, 4. yöntem ile elde edilen veri matrisinden üretilen model sonucu Büyük grup için %44, Ordo seviyesi için %57 olarak belirlenmiştir. Torbalamalı CART, SVM-RBF ve RF gibi karmaşık modeller, kullanılan örnekleme yöntemine bakılmaksızın, sırasıyla %69, %70 ve %71 ortalama genel doğrulukla orijinal toprak etüdüyle en tutarlı modelleri oluşturmuştur. Toprak etütlerinden eğitim verilerini çıkarmak için kullanılan örnekleme yöntemi, sonuçta ortaya çıkan tahminleri büyük ölçüde etkileyebilecektir Heung vd. (2016), alan ağırlıklı yaklaşımın en yüksek genel doğruluk ile sonuçlandığını bildirmişlerdir. Sınıf dengesizliği konusuna değinmek amacıyla kullanılan eşit sınıflı örnekleme yaklaşımının alan ağırlıklı yaklaşıma göre tahmin doğruluğunda azalmaya sebep olduğu bildirilmiştir.

Sayısal toprak haritalama için kullanılan makine öğrenme algoritmaları, genellikle ya sahada gözlemlenen toprak profilleri ile ya da toprak etüdü sonucu üretilen haritalama ünitelerinden elde edilen veriler kullanılarak eğitilir. Heung vd. (2017), Toprak sınıflarını haritalamak için eski toprak profil verilerinden ve toprak etüdü sonucu üretilen haritalama ünitelerinden elde edilen eğitim verilerinin kullanımının karşılaştırılması amacıyla yürüttükleri çalışmada, Kanada toprak sınıflandırma sistemine göre toprak büyük gruplarını tahmin etmek için bitkisel, iklimsel ve topoğrafik endeksleri içeren standart bir dizi çevresel değişken kullanmıştır. Toprak etüdü sonucu üretilen haritalama ünitelerinden türetilmiş eğitim veri seti, alan ağırlıklı bir yaklaşıma dayalı olarak tek bileşenli toprak etüdü harita birimlerinden rastgele örnekleme yoluyla geliştirilmiştir. Dört tek modelli algoritma (CART, k-en yakın komşu, çok terimli lojistik regresyon ve lojistik model ağacı) ve beş topluluk model algoritması (torbalama ile CART, torbalama ile k-en yakın komşu, torbalama ile çok terimli lojistik regresyon, torbalama ile lojistik model ağaçları, torbalama ve Rastgele Orman) karşılaştırılmış, haritalama ünitelerinden üretilmiş eğitim verileri kullanılarak yapılan tahminler, topluluk model algoritmalarında tutarlı bir şekilde doğruluk açısından daha yüksek bulunmuştur.

Cherlinka (2017), Ukrayna'da toprak verilerinin küçük ölçekte bulunduđu bölgede, yüksek çözünürlüklü sayısal yükseklik modelinden üretilen arazi parametrelerini tahmin edici değışken olarak kullanmış ve lojistik regresyonu ikiden fazla olası sınıf sonucu olan durumlara genelleştiren çok terimli lojistik regresyon kullanarak mevcut toprak haritasının mekânsal detayını geliştirmek için çalışma yürütmüştür. Tahmin haritaları ile mevcut haritanın ne kadar iyi eşleştiiğinin kappa istatistiğıyle değıerlendirdikleri çalışmada, %40 civarı bir doğruluk elde edildiğini bildirmişlerdir.

Camera vd. (2017), Akdeniz'deki üçüncü büyük ada olan Kıbrıs'ın güneyinde yayınlanmış 1:25000 ölçekli toprak haritasından (çalışma alanının %27'si) eğitim alanlarını kullanarak Güney Kıbrıs genelinin toprak sınıflarının oluşturulması amacıyla yaptıkları çalışmada çok terimli lojistik regresyon (MNLR) ve rastgele orman (RF) algoritmalarını kullanmışlardır. Çevresel değışkenler açısından, haritayı üretmek için SCORPAN formülünde dikkate alınan tüm toprak oluşum faktörlerini kapsayan 10 değışken kullandıkları bu çalışmada, RF'nin, ortalama doğruluklar göz önünde bulundurulduğunda toprak sınıf haritası için MNLR'den daha iyi bir doğruluk sağladığını bildirmişlerdir.

Mosleh vd. (2017), İran'ın Shahrekord ovasında sayısal toprak haritalama yaklaşımlarıyla toprak sınıflarını haritalamak için yapay sinir ağıları, güçlendirilmiş regresyon ağacı, rastgele orman ve çok terimli lojistik regresyon gibi farklı makine öğrenme tekniklerini karşılaştırdıkları çalışmalarında, farklı modellerin tüm taksonomik seviyelerde toprak sınıflarının tahmini için aynı yeteneğe sahip olduğunu, alt grup ve familya seviyelerinin doğruluklarında önemli bir düşüş eğilimi gözlemlendiğini bildirmişlerdir. Bununla birlikte, toprak sınıflarındaki varyasyonu tam olarak gösteremeseler de sayısal yükseklik modelinden elde edilen topoğrafik çevresel değışkenlerin, tüm taksonomik seviyelerde toprak sınıflarını tahmin etmek için en önemli çevresel ortak değışkenler olduğunu bildirmişlerdir. Açıklanamayan varyasyonların, zaman içinde yönetime bağılı olabilen, ortamdaki gözlemlenmemiş varyasyonlar tarafından kontrol edilebileceğini ve sayısal toprak haritalama yaklaşımlarının arazi kullanımını ve yönetimini etkileyen toprak özelliklerine odaklanan daha düşük taksonomik seviyelerde toprak sınıfları için yeterli tahmin doğruluğuna sahip olmadığını bildirmişlerdir.

Zeraatpisheh vd. (2017), İran'ın orta kesiminde bulunan yarı kurak bir bölgede dijital ve geleneksel toprak haritalama yaklaşımlarının etkinliğini incelediği çalışmada, çok terimli lojistik regresyon ve rastgele ormanı içeren iki sayısal toprak haritalama yaklaşımını, dört toprak taksonomisi seviyesinde, (ordo, alt ordo, büyük grup ve alt grup seviyeleri) geleneksel toprak haritalama yaklaşımı ile karşılaştırmıştır. Çok terimli lojistik regresyon, kategorik bağımlı değişkenler olarak farklı toprak taksonomisi seviyeleri (ordo, alt ordo, büyük grup ve alt grup seviyeleri) ile uzaktan algılama endeksleri, arazi özellikleri (niceliksel öngörücüler), jeomorfik birimler ve jeoloji haritaları (nitel tahmin ediciler) arasındaki ilişkileri modellemek için kullanıldığı bu çalışmada, çok terimli lojistik regresyon (MNLR) ve Rastgele orman (RF) modellemesinin sonuçları, jeomorfoloji haritasının ortak değişken olarak kullanıldığı senaryoların çoğu durumda harita kalitesi ve doğruluğu açısından jeomorfoloji haritası olmayan senaryolara göre daha iyi performansa sahip olduğunu göstermiştir. Çok terimli lojistik regresyon (MNLR) modelinde toprak ayarlı bitki örtüsü indeksi (SAVI), kil indeksi ve normalize bitki fark indeksi (NDVI), ordo, alt ordo ve büyük grup seviyelerinde en önemli çevresel değişkenler olarak belirlenmiştir.

Jeune vd. (2018), Haiti'nin batı bölgesinde yaklaşık 4300 km² alanda Dünya referans toprak sınıflama sistemi seviyesinde toprakların sayısal haritasını yapmak amacıyla yürüttükleri çalışmada çok terimli lojistik regresyon (MNLR) ve rastgele orman (RF) sınıflandırma algoritmalarını kullanmışlardır. Yükseklik ve yağış değişkenlerinin modelde önemli olduğunu belirtmişlerdir. Referans toprak seviyesinde çok terimli lojistik regresyon algoritması ile %55 genel doğruluk, %45 kappa katsayısı elde etmişlerdir. Çalışmadaki tüm toprak seviyeleri sınıflandırma doğruluğu, çok terimli lojistik regresyonda, rastgele orman tarafından sınıflandırılanlara eşit veya onlardan daha yüksek bulunmuştur. Eğitim aşaması sırasında toplam beş gözlem ile temsil edilen Luvisols+Chernozems haritalama biriminin düşük temsil edilebilirliği, öğrenmede yetersiz olmuş ve %0 doğrulukla sınıflandırılmıştır.

İlgilenilen bir bölgede ayrıntılı harita veya toprak bilgisine erişilemediğinde, bilgi edinmenin bir yolu, toprak bilgisine sahip diğer benzer bölgelerden üretilebilecek modellerle benzer ilgili bölgeler için bilgi çıkarmaktır. Afshar vd. (2018), İran'ın kurak bölgelerinde bölgesel ölçekte çok terimli lojistik regresyon kullanarak toprak büyük gruplarının sayısal haritasını yapmak amacıyla yürüttükleri çalışmada, iki bölge

arasında toprak oluşturan faktörlerin homojenliğini de test etmişlerdir. Zarand bölgesinde oluşturulan çok terimli lojistik regresyon modelinin, Zarand ile benzer topoğrafya ve jeolojiye sahip Bam bölgesindeki toprak sınıflarının tahmin edilip edilemeyeceği ve toprak haritalarının yapım maliyetlerine etkisinin araştırıldığı bu çalışmada, %60 düzeylerinde kappa değerleri elde edilmiştir. Üretilen modelin benzer farklı alanlarda uygulama metodolojisinin, toprak gözlemlerinin yeterli olmadığı alanlarda toprak sınıflarını tahmin etmede oldukça yararlı olduğunu bildirmişlerdir.

Toprak dağılımının doğası dikkate alındığında, toprak sınıfı haritalamasında önemli bir modelleme konusu dengesiz sınıf gözlemleridir. Sharififar vd. (2019), Bir bölgedeki gözlemlenen toprak sınıflarındaki dengesiz veri sayısının, az sayıda olan sınıflarının eksik tahmin edilmesine ve tahmin haritalarında çoğunluk sınıflarının fazla tahmin edilmesine neden olabileceğini bildirmiştir. Bu durumu incelemek amacıyla, İran'ın kuzeybatısında yarı kurak bir bölgede, USDA toprak taksonomisine göre dengesiz gözlem dağılımına sahip 8 büyük toprak grubunun bulunduğu 12000 ha alanda karar ağaçları (DT), rastgele orman (RF) ve çok terimli lojistik regresyon (MNLR) ile tahmin edilen sınıf haritalarının karşılaştırmasını yapmışlardır. Karışıklık indeksi (CI), 0 ise veya sıfıra yaklaştıkça bir sınıf hakimdir ve çok az karışıklık mevcuttur, ancak karışıklık indeksi (CI), 1'e yaklaştıkça, her iki sınıf olasılık değeri neredeyse eşittir ve ilgili alanın neredeyse ait olduğu sınıf hakkında net bir belirsizlik vardır (Burrough vd., 1997). Sınıfların dengelenmesi, karışıklık indeksini azaltarak üretilen haritalarda 3 modelin tamamının belirsizliğinde kayda değer bir düşüşe neden olmuştur. 3 modeli karşılaştırılması sonucunda karar ağaçları, veri işlemeli ve veri işlemez yöntemde, eğitim ve test setlerinde en yüksek doğrulukları sağlamıştır. Sınıfların dengelenmesi sonucunda MNLR modeli sonucunda, sınıfların 5'inde oluşma olasılıklarında gelişme görülmüş, bu sınıflardan bir tanesi olan sınıf, dengesiz sınıflar kullanıldığında ortaya çıkma olasılığı elde etmemiştir.

Cherlinka (2019), Ukrayna'da yaklaşık 30 km² alanda sayısal yükseklik modelinden ürettiği çevresel değişkenler ile toprak kategorilerini sınıflandırmaya yönelik yaptığı çalışmada, 11 farklı sınıflandırma algoritmasını karşılaştırmıştır. Doğruluk değerlendirilmesine göre yaptığı bu karşılaştırmada çok terimli lojistik regresyon metodunun kappa katsayısının, eğitim ve test setlerinde %80-%90 aralığında olduğunu bildirmiştir.

Silva vd. (2019), Brezilya'nın güneydoğusundaki Poses havzasında 1200 ha alanda yüksek çözünürlüklü sayısal yükseklik modelinden üretilen değişkenlerle topoğrafya faktörünü ve Sentinel 2A MSI uydusundan üretilen indislerle bitki örtüsü faktörünü temsil edecek şekilde toprak kategorik seviyelerinin sayısal toprak haritasını üretmek amaçlı yaptıkları çalışmada, 3 farklı tahmin algoritması (Çok terimli lojistik regresyon (MNLR), C5 karar ağacı (C5-DT) ve Rastgele orman (RF)) kullanmışlardır. Çok terimli lojistik regresyonun kappa katsayısının %20 olduğunu bildirmişlerdir. Moura-Bueno vd. (2019), Brezilya'nın güney bölgesinde 12 km² alan kaplayan karmaşık bir arazide sayısal toprak haritalama ile toprak sınıfını tahmin etmek için tahmin modellerinin (karar ağacı (DT) (J48 algoritması), rastgele orman (RF), destek vektör makinesi (SVM) ve çok terimli lojistik regresyon (MNLR)) performansını belirlemek üzere yaptıkları çalışmada, modellerin doğruluğunu kappa katsayısı (K), genel doğruluk ile değerlendirmişlerdir. Çevresel değişken verisetinin de farklı şekillerde kombinasyonunun sağlandığı çalışmada çok terimli lojistik regresyon algoritması için kappa değerleri eğitim seti için %56-61 aralığında, test seti için %44-46 aralığında belirlenmiştir.

Piccini vd. (2019), İtalya'nın orta bölümünde yer alan ve yaklaşık 17200 km² alan kaplayan Latium bölgesinde, derinlik sınıfları, drenaj sınıfları, üst toprak tekstür grubu, çakıl durumu gibi kategorik toprak özelliklerini, arazi yüzeyi parametreleri (Sayısal yükseklik modelinden üretilmiş) ile tahmin etmek amacıyla çok terimli lojistik regresyon modelini kullanmışlardır. Landsat uydu görüntüsün etkisini de görmek amacıyla iki farklı veri setinde yürüttükleri bu çalışmada, etkili toprak derinliği sınıflarının tahmininde kappa katsayısını Landsat uydu görüntüsü varlığında %83, Landsat uydu görüntüsü yokluğunda %78 olarak belirlemişlerdir. Yine bu çalışmada üst toprak tekstür sınıflarının tahmininde kappa katsayısını Landsat uydu görüntüsü yokluğunda %81, Landsat uydu görüntüsü varlığında %90 olarak belirlemişlerdir.

Taghizadeh-Mehrjardi vd. (2019), İran'da Entisol ve Aridisol ordolarının mevcut olduğu 150 km² alanda, sayısal yükseklik modeli, uzaktan algılama verileri ve jeomorfoloji haritasını çevresel değişken olarak kullandıkları çalışmada, çok terimli lojistik regresyon (MNLR), yapay sinir ağları (YSA), destek vektör makinesi (SVM), karar ağacı (DT), rastgele Orman (RF), bayes ağları (BN) ve seyrek çok terimli lojistik

regresyon (SMnLR) algoritmaları ile sayısal toprak haritalama çalışması gerçekleştirmişler ve model performanslarını genel doğruluk ve kappa katsayısı ile karşılaştırmışlardır. Ordo seviyesinde (%87), alt ordo (%52), büyük grup (%46) ve alt grup (%41) seviyelerinde genel doğruluk göz önünde bulundurulduğunda en iyi performansı rastgele orman (RF) göstermiş, En kötü performans gösteren model sonuçları, ordo (%.64), alt ordo (%40), büyük grup (%34) ve alt grup (%34) seviyelerinde çok terimli lojistik regresyon (MNLR) kullanılarak elde edilmiştir.

Van Zijl, vd. (2019), Güney Afrika'da yerleşim baskısı altındaki 12000 hektar bir kentsel alan için hidropedolojik bir değerlendirme yapmak amacıyla sayısal toprak haritalama yöntemini uyguladığı çalışmasında, Arazi türevleri, bant oranları, kurak ve yağışlı mevsim NDVI değerlerini çevresel değişken olarak kullanmıştır. Çok terimli lojistik regresyon algoritması ile yapılan 142 toprak gözlemini dikkate alarak hidropedolojik toprak haritası oluşturulmuş, toprak haritasının, kabul edilebilir bir %69 genel doğruluğa ve %59'luk bir kappa değerine sahip olduğunu bildirmiştir.

Rasaei vd. (2019), bir dizi eski toprak profili ve SYM verilerini, çok terimli lojistik regresyon (MNLR) ve bayesian maksimum entropi (BME) modellerini kullanarak WRB (Dünya Referans Sistemi) toprak sınıflarının mekânsal tahminini oluşturmuşlardır. MNLR için eğim ve vadi derinliğinin toprak sınıflarını tahmin etmek için en önemli ortak değişkenler olduğunu, bununla birlikte MNLR modelinin Cambisol ve Luvisol sınıflarını doğru bir şekilde tahmin edemediğini bildirmişlerdir.

Du vd. (2020), mekânsal tahminde sınırlı örnekleri bulunan alanlardaki çalışmaları desteklemek amaçlı kullanılabilecek yarı denetimli bir makine öğrenimi yaklaşımı sundukları çalışmada, yalnızca alan örneği yaklaşımlarıyla (karar ağaçları, lojistik regresyon ve destek vektör makineleri) yapılan haritalama çalışmaları ile karşılaştırıldığında, önerilen yaklaşımın kullanılarak üretilen haritalarda, toprak türlerinin mekânsal varyasyonunun daha iyi yakalanabildiğini ve sınırlı örneklerle daha yüksek doğruluk elde edilebileceğini bildirmişlerdir.

Forghani vd. (2020), İran'ın güneydoğusunda kurak bir taşkın ovasındaki Dünya referans grubu toprak sınıflarının mekânsal tahminine yönelik yaklaşık 600 km² bir alanda yaptıkları çalışmada, çok terimli lojistik regresyon (MNLR) ve rastgele orman

(RF) algoritmalarını karşılaştırmışlardır. Birinci seviyede Cambisol, Fluvisol ve Solonchak'ı içeren üç birinci seviye referans toprak grubu (RSG'ler) ve ikinci seviyede 18 WRB toprak grubu belirlenen alanda, çok terimli lojistik regresyon (MNLR) modeli sonucu haritalama neticesinde referans toprak grubu ilk seviyesindeki genel doğruluğunu, %53, kappa katsayısını %26 olarak belirlemişlerdir. Çok terimli lojistik regresyon (MNLR) modeli sonucu WRB'nin ikinci seviyesindeki genel doğruluğunu, %11 ve kappa katsayısını %0 olarak belirlemişlerdir. MNLR modelinin WRB'nin ilk seviyesinde daha iyi performansa sahip olduğunu (genel doğruluk %53), ancak RF modelinin WRB'nin ikinci seviyesinde daha iyi tahmin gösterdiğini (genel doğruluk %21) bildirmişlerdir. WRB'nin ikinci seviyesini tahmin etmede modellerin doğruluğunu artırmak için örneklem boyutunun artırılması önerilmektedir.

Asgari vd. (2020), yarı kurak bir bölgede bulunan USDA toprak büyük gruplarının tahmin edilmesinde yersel spektrometrik veriler ve uzaktan algılanan verileri çevresel değişkenlerle birleştirmenin etkinliğini değerlendirmek üzere yaptıkları çalışmada, destek vektör makinesi (SVM) ve çok terimli lojistik regresyon (MNLR) olmak üzere iki tahmin modeli ile sayısal toprak haritası oluşturmuşlardır. MNLR (kappa %78) sınıflandırma algoritmasının SVM'den (kappa %66) daha iyi performans gösterdiğini bildirmişlerdir. Renk, normalize fark bitki indeksi (NDVI), toprak ayarlı bitki örtüsü indeksi (SAVI), jeomorfoloji haritası ve eğim de dahil olmak üzere bazı arazi özellikleri en önemli değişkenler arasında bulunmuştur. Jeo-uzamsal verileri ve proksimal (yersel) algılama bilgisini çok değişkenli sınıflandırma algoritmalarında birleştirmenin toprak sınıflandırma doğruluğunu hızlı ve uygun maliyetli bir şekilde iyileştirebileceğini bildirmişlerdir.

Du Plessis vd. (2020), Güney Afrika'nın doğusunda 83000 hektarlık alanda oyuntu erozyonunun hangi derecede meydana gelebileceği alanları belirtmek için sayısal toprak haritalama yöntemleriyle T35DE kuaterner havzaları için bir toprak ilişki haritasını oluşturmak amaçlı yaptıkları çalışmada, elde edilen toprak verileri ve o noktalardaki çevresel değişken değerlerinin bir veri matrisi oluşturulduktan sonra, çok terimli lojistik regresyon modellemesi ile toprak haritalama işlemlerini gerçekleştirmişlerdir. Haritanın %64'lük bir genel doğruluğu ve %38'lik bir kappa katsayısı olduğunu bildirmişlerdir.

Rasaei vd. (2020), İran'ın Doğu Zagros bölgesinde yer alan 10480 km²'lik alanda yaptıkları çalışmada, dört taksonomik seviyedeki (ordo, alt ordo, büyük grup ve alt grup) toprak sınıflarını, iki set (ortak değişken olarak eski toprak haritasını kullanılmadan oluşturulan veri seti 1 ve kullanıldığında veri seti 2) eş değişkenler dikkate alınarak 123 eski toprak profiline dayalı olarak eğitilen çok terimli lojistik regresyon modeli kullanarak haritalamışlardır. Genel doğruluk ordo seviyesinde eski toprak haritasını kullanılmaması (veri seti 1) durumunda %73, eski toprak haritasını kullanılması durumunda (veri seti 2) %95 olarak belirlenmiştir. Bu doğruluk artışı tüm taksonomik seviyelerde oluştuğunu bildirmişlerdir.

Teorik olarak, yeterli sayıda ve sahada gözlemlenen sınıfların yeterli mekânsal dağılımı göz önüne alındığında, çok terimli lojistik regresyon, yüzlerce benzersiz taksonomik varlık ile daha düşük taksonomik seviyelerde toprak sınıflarını haritalamak için kullanılabilir (Hengl ve Macmillan, 2019).

2.4.1.2. Farklı sınıflandırma algoritmaları kullanılarak yapılan sayısal toprak haritalama çalışmaları

Çevresel planlama ve modelleme için artan yüksek çözünürlüklü mekânsal toprak bilgisi talebi doğrultusunda, yüksek kaliteli dijital toprak haritaları elde etmek için hızlı ve doğru tahmin yöntemlerine ihtiyaç vardır. Behrens vd. (2005), Almanya'nın Rhineland-Palatinate bölgesinde yaklaşık 600 km² alanda toprak sınıflarını mekânsal olarak tahmin edebilen yapay sinir ağlarına (YSA) dayalı bir metodolojinin geliştirilmesine yönelik yaptıkları çalışmada, bir toprak biriminin oluşumunu tanımlamak ve YSA'yı eğitmek için 69 farklı arazi özelliği, 53 jeolojik-petrografik birim ve 3 tür arazi kullanımı gibi mevcut harita ve veri tabanlarından örnekleme noktalarına dair bilgiler çıkarılmış ve modellenmiştir. Hem eğitim hem de doğrulama alanlarında tüm toprak birimlerinde ortalama doğruluk %92 olarak belirlenmiş ve genel olarak iyi bir tahmin doğruluğuna sahip olduğu vurgusu yapılmıştır.

Moran ve Elisabeth (2002), Güçlendirilmiş karar ağacı ve çevresel değişkenlerden çıkarılan mekânsal ve bağlamsal bilgileri kullanarak toprak sınıflarının mekânsal haritasını yapmak amacıyla yürüttükleri araştırmada, alan ağırlıklı ve eş sayıda örnekleme metodolojilerini karşılaştırmışlar, alan ağırlıklı örneklemenin kappa

katsayısı %64 olarak belirlemişlerdir. Eş sayıda örnekleme metodunun kappa katsayısı %52 olarak bildirmişlerdir.

Behrens ve Scholten (2006), yapay sinir ağları (YSA), destek vektör makineleri (SVM), doğrusal regresyon, vektör niceleme modelleri (LVQ) ve sınıflandırma ağaçları (CT) dahil olmak üzere istatistik ve bilgi teorisinden farklı veri madenciliği tekniklerinin ve algoritmalarının yeteneklerini karşılaştırdığı çalışmalarında YSA'ların toprak sınıflarını tahmin etmek için genel olarak en iyi yöntem olduğunu belirlemişlerdir.

Grinand vd. (2008), arazide kontrol edilmeyen konumdaki toprak dağılımını tahmin etmek için bir toprak haritasından çıkarılan toprak-arazi desenini kullanma potansiyelini araştırmayı amaçladıkları çalışmada güçlendirilmiş sınıflandırma ağacı algoritmasını kullanmışlardır.

Sayısal toprak haritalamada tahmin ve sınıflandırma için nicel teknikler hızla gelişmeye devam etmiştir. Kovačević vd. (2010), Destek vektör makineleri (SVM), lojistik regresyon (LR) ve Çok terimli naive bayes (MNB) algoritmalarını kullanarak dijital olarak toprak tipi sınıflandırması yapmak amacıyla yürüttükleri çalışmada, Dünya Referans Sisteminde (WRB) 2. seviyede tanımlanan 8 Büyük toprak grubunu haritalandırmışlardır. SVM (kappa %50) yöntemi, tahmin doğruluk değerleri ile ilgili olarak kappa katsayısı göz önüne alındığında LR'den (kappa %45) biraz daha iyi performans göstermiştir. MNB, (kappa %36) en kötü performans gösteren sınıflandırıcı olarak belirlenmiştir.

Roecker vd. (2010), Geleneksel toprak etüdü ile sayısal toprak haritalama yaklaşımlarının niteliksel bir karşılaştırmasını yapmak amacıyla yürüttüğü çalışmada, geleneksel toprak etüdü yaklaşımıyla oluşturulan üçüncü dereceden bir toprak haritasının sayısal toprak haritalama yoluyla oluşturulan bir haritayla ne kadar karşılaştırılabilir sorusunun cevabının arandığı çalışmada, her iki yaklaşım da sadece farklı miktarlarda mekânsal detaylı veri üretmenin yanında, aynı zamanda harita birimleri içinde farklı kompozisyonlar ve toprak bileşenleri de üretmiştir. ABD'deki mevcut toprak etüdü verisi göz önüne alındığında, sayısal toprak haritalama metodolojilerinin sonuçlarının, haritalama birimi kompozisyonlarını tahmin etmeye ve

tasvirleri yönlendirmeye yardımcı olacak bir araç olarak kullanılabileceğini bildirmişlerdir.

Sun vd. (2011), Hong Kong’da geleneksel tarzda yürütülen bir toprak etüdünden elde edilen eski toprak verilerine dayanarak, Hong Kong'un dağlık bölgeleri için toprakların ordo seviyesinde haritalarını üretmek için sayısal toprak haritalama yöntemini uygulamışlardır. Karar ağacı analizi ve doğrusal diskriminant analizi yöntemlerini karşılaştırmışlar, doğrusal ayırt edici modellerin, karar ağacı modellerinden daha iyi performans gösterdiğini bildirmişlerdir.

Jafari vd. (2014), İran’ın güneydoğusundaki kurak bir bölgede sınırlı nokta veri setini kullanarak güçlendirilmiş regresyon ağaçları (BRT) ile büyük toprak gruplarının mekânsal tahminini yapmak amacıyla yürüttükleri çalışmada, dolaylı bir yaklaşım olarak lojistik-BRT ve toprak sınıfı haritaları üretmek için doğrudan bir yaklaşım olarak çok sınıflı-BRT metotlarını karşılaştırmışlardır. Dolaylı tahminde, ilgili teşhis horizonlarının oluşumu ilk olarak haritalanmış ve daha sonra, teşhis horizonlarının varlığı veya yokluğu birleştirilerek piksel bazlı bir sınıflandırma için çeşitli haritalar birleştirilmiş ve sınıflandırma için gösterge haritalarının büyük gruplar halinde birleştirilmek amacıyla, teşhis edici horizonların oluşumunu bir toprak büyük grubuna bağlamak için uzman temelli bir karar ağacı tanımlamışlardır. Jeomorfoloji haritasının tahmin doğruluğuna önemli ölçüde katkıda bulunduğunu bildirdikleri çalışmada, değişken veri setinden jeomorfoloji haritası çıkarıldığında, tahmin doğruluğunun hem dolaylı hem de doğrudan modellerde büyük ölçüde azaldığını, bu durumun özellikle mevcudiyeti jeomorfik yüzeylerle doğrudan ilişkisi olan toprak sınıfları için daha belirgin olduğunu bildirmişlerdir.

Pahlavan-Rad vd. (2014), İran'ın kuzeyinde 85000 ha alanda toprak taksonomisi büyük grup, alt grup ve seri seviyelerinde rastgele orman ve koşullu latin hiperküp örneklemesini kullanarak toprak etüdü haritalarını güncellemek amacıyla yaptıkları çalışmada, genel hata oranlarını, büyük grup, alt grup ve seri seviyeleri için sırasıyla %49, %52 ve %57 olarak belirlemişlerdir. Toprak ayarlı bitki indeksi, geleneksel toprak seri haritası ve jeomorfoloji haritası, her taksonomik seviye için en önemli ortak değişkenler olarak belirlenmiştir. Güncellenen toprak serisi haritasının, mevcut geleneksel toprak serisi haritasından %13 daha doğru olduğunu bildirmişlerdir.

Heung vd. (2014), Rastgele orman algoritması ile bölgesel ölçekte toprak anamateryalinin haritalanması amacıyla yaptığı çalışmada, tahmine dayalı ana materyal haritasını, eski toprak etüdü haritaları ve 307 yersel gözlem noktası ile karşılaştırmalar yapılmış ve eski toprak etüdü haritalama ünitelerinden elde edilen verilerle doğrulandığında %90'lık bir kappa katsayısı ve yersel gözlem noktası ile doğrulandığında ise %80'lik bir kappa katsayısı ile sonuçlandığını bildirmişlerdir.

Bulmer vd. (2016), Kanada'nın British Columbia bölgesinde eski toprak verilerini kullanarak rastgele orman algoritması ile geliştirilmiş ana materyal haritalaması yapmak amacıyla yürüttükleri çalışmada, toprak ana materyallerini tahmin etmek için eğitim alanlarını, eski arazi, toprak ve ekosistem haritalarından tek bileşenli haritalama ünitelerini kullanarak belirlemişler ve eğitim noktalarını, 100 metrelik bir dijital yükseklik modelinden (SYM) türetilen 18 topoğrafik eş değişken ile çakıştırılması sonucu elde edilen veri matrisi ile rastgele orman algoritmasını kullanarak modellemişlerdir. Genel olarak, düğüm saflığını iyileştirmek için en önemli değişkenin, topoğrafik çeşitliliği vurgulayan yükseklik olduğunu belirlemişlerdir.

Bodaghabadi vd. (2016), İran'ın Chah-Sefid bölgesinde yaklaşık 1000 ha bir alanda, sayısal toprak haritalama (STH) için yapay sinir ağlarını (YSA) eğitmek amacıyla örneklenen pedonların (nokta verileri) mekânsal temsilini genişletmek için polipedon kavramı kullandığı çalışmada, girdi veri tabanı olarak, 7 farklı toprak serisine ait 97 toprak profili ve 15 adet sayısal yükseklik modelinden üretilmiş (SYM-10 m) indisleri kullanılmıştır. Bir pedon, her zaman olduğu gibi bir piksel ile temsil edildiğinde, giriş veri setine aktarılacak üzere yalnızca bir değer çıkarılması ile 2×2 , 3×3 , 4×4 , 5×5 ve 6×6 piksel matrislerinden çıkarılan polipedon verilerinin karşılaştırıldığı bu çalışmada, toprak veri tabanının genişlemesi ile (1×1 hücreden 6×6 hücreye kadar), eğitim verisinde genel doğruluğun arttığını, ancak test ve validasyon verilerinde genel doğruluğun azaldığını bildirmişlerdir.

Mirakzehi., (2018), İran'ın doğusunda Sistan bölgesinde 60000 ha bir alan için rastgele orman (RF) tekniğini kullanarak toprak büyük grupları, alt grupları ve familyayı içeren taksonomik toprak sınıflarını tahmin etmişlerdir. Kanal ağları, vadi derinliği, NDSI ve havza alanı en önemli ortak değişkenler olarak belirlenmiştir. Çalışılan alanda toprak oluşumunu ve gelişimini etkileyen ana faktörlerin akarsu aktiviteleri olduğunu

göstermiştir. Toprak büyük grupları, alt gruplar ve familya seviyeleri için genel doğruluk sırasıyla %46, %44 ve %46 olarak belirlendiği çalışmada, kanal ağları çevresel değişkeninin alüvyal alandaki tüm taksonomik seviyelerde en önemli ortak değişken olduğunu ve RF'nin kurak alüviyal bölgelerdeki toprak sınıflarını haritalamak için yüksek potansiyel gösterdiğini bildirmişlerdir.

Shukla vd. (2018), Rastgele Orman (RF) modelinin farklı 2 sınıflandırma algoritması ile karşılaştırılması ve etkin bir şekilde uygulanmasına yönelik Hindistan'da toprak sınıflandırmasında performansını değerlendirmeyi amaçlayan çalışmalarında, rastgele orman algoritmasının diğer 2 algoritmadan daha doğru sonuçlar verdiğini bildirmişlerdir.

Poppiel vd. (2019), yersel spektrometrik veriler ve uzaktan algılanan verilerden toprak sınıfı haritalaması amacıyla yürüttükleri çalışmada, geliştirilen çoklu son üye spektral karışım analizi (MESMA) tabanlı metodoloji ile üst toprağın spektrumlarına dayalı dijital pedolojik haritalama yapılabileceğini ve MESMA'dan türetilen dijital toprak haritasının doğruluğunun %73 kappa katsayısı ile sonuçlandığını bildirmişlerdir.

Assami ve Aissa (2019), toprak bilgisinin az olduğu Cezayir'in Sahra bölgesinde makine öğrenimi modellerini sayısal toprak haritalamada test etmek amacıyla yaptıkları çalışmada, toprak sınıflarını tahmin etmek ve haritalamak için altı makine öğrenme algoritmasını karşılaştırmışlardır. Dünya referans siteminde toprak büyük grupları, modellemede girdi verileri olarak kullanılmıştır. Yükseklik ve üst toprak tane büyüklük indeksi çevresel değişkenleri rastgele orman (RF) algoritmasında en önemli değişkenler olarak belirlenmiştir.

Esfandiarpour-Boroujeni vd. (2020a), Düz alanlarda toprak sınıflarını tahmin etmek için karar ağacı ve vektör niceleme modellerinin hata ve belirsizlik sonuçlarını karşılaştırmak amacıyla yürüttükleri çalışmada, Karar ağacı (DT) modelinin, vektör niceleme modelinden (LVQ) daha iyi sonuçlar verdiğini, bununla birlikte tahmin edilecek toprak sınıflarının sayısı düşük olduğunda, LVQ modelinin daha güvenilir sonuçlar verdiğini ve her iki öğrenme algoritmasının da tahmin edilecek taksonomik seviye daha ayrıntılı olduğunda modellerin belirsizliğinin arttığını bildirmişlerdir. Bir

haritanın doğruluğu, ayrıntı seviyesi (yani, sınıflandırma sistemi) ve haritalanacak kategorilerin değişkenliği dahil olmak üzere çok çeşitli faktörlere bağlıdır. Congalton ve Green (2019), %85'lik bir genel doğruluğu kabul edilebilir bir eşik olarak bildirmektedirler. Geleneksel toprak haritalamada, bir harita birimindeki birbirine benzemeyen küçük bileşenlerin toplam miktarı genellikle %15 ile %25 arasındadır (Soil Survey Division Staff, 2017). Esfandiarpour-Boroujeni vd. (2020a), bu nedenle, bu aralığın, yani toplam çalışma alanını bir harita birimi olarak düşünüldüğünde, her taksonomik seviyede %75 ile %85 arasındaki bir genel doğruluğun eşik değeri olarak kullanılabileceğini bildirmektedirler.

Leenaars vd. (2020), Etiyopya'nın dağlık bölgesinde 26820 km² alanda rastgele orman modeli kullanarak yaptıkları haritalama çalışmasında Dünya referans sistemi (WRB) seviyelerinde %58'lik bir doğruluk elde edildiğini bildirmişlerdir. En önemli çevresel değişken olarak, 1: 1 000 000 ölçekteki Etiyopya'nın jeomorfoloji ve toprak haritası olarak belirlenmiştir.

Esfandiarpour-Boroujeni vd. (2020b), İran'ın Shahrekord ovasında toprak sınıflarının tahmini için farklı sayısal toprak haritalama yöntemlerinin değerlendirilmesi amacıyla yaptıkları çalışmada, toprak taksonomisi ve Dünya referans sistemi (WRB)'ne göre farklı seviyelerinde sınıflandırılmış alanlarda, karar ağacı (DT), rastgele orman (RF), yapay sinir ağı (YSA) ve destek vektör makinesi (SVM) algoritmalarının doğruluğu ve belirsizliğinin genel doğruluk ve karışıklık indeksi (CI) ile değerlendirip karşılaştırmışlardır. Algoritma performansı, taksonomik seviyelerde detay bilgisi arttıkça (yani, ordodan aile seviyesine veya referans toprak gruplarında (RSG'ler) ikinci seviyeye doğru), karışıklık indeksi artarken genel doğruluk değerlerinin azaldığını bildirmişlerdir. Hem RF hem de DT algoritmalarındaki genel doğruluk değerlerinin yakınlığına rağmen, DT algoritması daha düşük karışıklık indeksi (CI) değeri nedeniyle daha verimli olmuştur. Üst taksonomik seviyelerde, SVM algoritması diğer algoritmalara kıyasla daha iyi performans gösterirken, DT algoritması daha yüksek sayıda sınıf örneklerinin olduğu, yani daha fazla alan kaplayan sınıfların tahmininde daha iyi sonuçlar verdiğini bildirmişlerdir.

Maleki vd. (2020), İran'ın Golestan eyaletinde 5390 ha alanda çevresel eş değişkenler kümesini ve toplam 64 toprak profilini ilişkilendirerek bir toprak haritasının tahminini

gerçekleştirdikleri çalışmada, rastgele orman (RF) modelini kullanmışlardır. Alt ordo seviyesinde genel doğruluk %76 ve kappa %56, büyük grup seviyesinde genel doğruluk %72 ve kappa %51, alt grup düzeyinde genel doğruluk %54 ve kappa %31 ve familya düzeyinde genel doğruluk %40 ve kappa %23 olarak belirlenmiştir. Belirsizlik sonuçları, karışıklık indeksi (CI) olarak bildirilmiş, belirsizliğin daha düşük taksonomik kategorilere (yani, alt ordodan familya düzeyine) doğru artma eğiliminde olduğunu göstermişlerdir.

Dotto vd. (2020), toprakları dijital olarak sınıflandırmak amacıyla toprak bilimcilerin toprak-çevre etkileşimleri hakkındaki bilgisini modelleyebilmek için, spektral veriler, iklim ve topoğrafya verilerini çevresel değişken olarak kullanmış, Dünya referans sisteminin (WRB) toprak sınıflarını, belirtilen üç değişken kullanılarak rastgele orman algoritması ile sınıflandırmışlardır. Yalnızca spektral verileri kullanarak genel doğruluğu %83, spektral, iklimsel ve arazi değişkenleri dahil edildiğinde genel doğruluğu %88 olarak belirlemişlerdir.

Toprak haritalama için makine öğreniminin geniş çapta benimsenmesi, veri kullanılabilirliğindeki artış, mekânsal verilere erişim kolaylığı ve bunları analiz etmek için hesaplama araçlarının yardımıyla yazılım çözümlerinin geliştirilmesi sayesinde mümkün olmuştur (Wadoux vd., 2020). Pedolojik bilginin makine öğrenimi algoritmasına dahil edilmesi veya kalibre edilmiş makine öğrenimi modelinin yorumlanabilirliği gibi birkaç ek zorlayıcı yönün dikkate alınması gerekir (Wadoux vd., 2020). Bu zorlukların üstesinden gelmek, makine öğreniminin toprak biliminde güvenilirlik ve bilimsel tutarlılık kazanması için kritik öneme sahiptir (Ma vd., 2019; Wadoux ve McBratney, 2021) Bu kapsamda denetimli sınıflandırma yöntemleri uygulanırken özellikle modelde önemli olan değişkenlerin uzman toprak bilimci tarafından alan göz önünde bulundurularak değerlendirilmesi gerekmektedir. Sadece model sonucu önem arz eden değişkenlerin alanda karşılık bulmaması gibi durumlar var ise dikkatle kontrol edilmelidir. Model doğruluğun göstergelerine sıkışıp kalmak, makine öğreniminin toprak haritalamada esas rolü olan bilgi keşfi amacının unutulmasına yol açabilecektir.

2.4.2. Denetimsiz öğrenme algoritmaları

Denetimsiz sınıflandırma, bilgisayar otomasyonuna en çok dayanan tahmin yöntemidir ve alanı kapsayan toprak gözlemleri (yani eğitim verileri) gerektirmeyen tek yöntemdir. Algoritma, istatistiksel olarak belirlenmiş ölçütlere dayanarak, veri ve grup piksellerini, benzer karakteristiklere sahip benzersiz kümeler (sınıflar) ayırmaktadır (Duda vd., 2001). Ortaya çıkan sınıf tanımları, yalnızca toprak oluşumu değişkenlerini temsil eden öngörücü verilere ve sınıflandırmanın yürütüldüğü sırada tanımlanmış birkaç parametreye bağlıdır. Elde edilen sınıflar, toprak-çevre ilişkileri açısından anlamlı olup olmadıklarını belirlemek için yorumlanmalıdır (Brown vd., 2017).

Yinelemeli kendini düzenleyen veri analizi tekniği (ISODATA) (Tou ve Gonzalez, 1974) ve k ortalamaları (MacQueen, 1967; Hartigan ve Wong, 1979) en yaygın kullanılan denetimsiz sınıflandırma algoritmalarıdır ve birçok yazılım paketinde bulunur. ISODATA, k-ortalama algoritmasının bir modifikasyonudur. Her kümedeki son noktaların tanımlandığı sınırdaki, her piksel konumunun sınıf atamasındaki değişiklik en küçük olana kadar kümeler oluşturan ve pikselleri sınıflandıran yinelemeli bir işlem kullanılmaktadır.

Alan hakkında önceden bilgi sahibi olmak gerekmediğinden, denetimsiz sınıflandırma, alan örneklemesini yönlendirmeye ve haritalama birimi kavramlarını geliştirmeye yardımcı olabilecek kullanışlı bir keşif aracıdır. Bununla birlikte, kümelerin nasıl tanımlandığı üzerinde çok az kontrol olduğundan, sonuçların yorumlanması zor olabilir.

K-ortalamaları, çok değişkenli özellik uzayında nesnelerin kompakt kümelerini bulmak için kullanılan, köklü bir kümeleme analizi yöntemidir (Hartigan ve Wong, 1979). Kümeler, merkezler olarak adlandırılan çok değişkenli araçlarıyla temsil edilir ve yöntem, nesneler ile en yakın ağırlık merkezi arasındaki ortalama kare mesafeyi en aza indirmeyi amaçlamaktadır.

Toprak etüdünün örnekleme aşamasında mevcut çevresel verileri kullanmak istemediğimiz durumlarda veya toprak niteliği ile korelasyondan emin olmadığımız

durumlarda, yapabileceğimiz en iyi şey noktaları coğrafi uzayda dağıtmaktır. Brus vd. (2006), k ortalamaları algoritmasını, farklı bir amaç için kullandıkları çalışmada, raster verilerde bu algoritmanın çalıştırılması sonucu, kümelerin merkezleri olarak belirlenen noktanın x ve y koordinatlarını örnekleme noktası olarak önermişlerdir.

Denetimsiz sınıflandırma, toprak etüdünün keşif veya ön haritalandırma aşamasında uygulanabilmektedir. İlk alan örneklemesinde yer belirlemeye yardımcı olabilir, haritalanmış ve haritalanmamış alanları karşılaştırmada yararlı olabilir.

Carré ve McBratney vd. (2006), toprak ve peyzajın bir bütün olarak ele alındığı “terron” isimli yeni bir kavram sundukları çalışmada terron’u toprağı ve araziye aynı anda birleştiren bir toprak-çevre varlığı olarak tanımlamışlardır. Denetimsiz öğrenme algoritmalarından bulanık k ortalama algoritması bu çalışmada terronların mekânsal olarak tanımlanmasında ve haritalanmasında kullanılmıştır.

Saunders ve Boettinger (2007), yaklaşık 600 km² alanda mevcut toprak-arazi-bitki örtüsü ilişkilerini temsil edebilecek modelleri belirlemek için metodolojinin ön aşamasında üç toprak iyileştirme bant oranı, fraksiyonel bitki örtüsü ve eğim çevresel değişkenlerini tek bir dijital görüntü formatında çakıştırmış ve bu görüntüde beş ve on sınıf denetimsiz sınıflandırma yürütmüştür. Beş sınıfın çok genel olduğunu, on sınıf ise arazideki toprak-peyzaj ilişkilerini belirlemek için arzu edilen bir ayrıntı düzeyi sağladığını bildirmiştir.

Cole ve Boettinger (2007), Wyoming'in Powder Nehri Havzası'ndaki toprak dağılımını tahmin etmek ve haritalamak için coğrafi bilgi sistemleri (CBS), uzaktan algılama ve modellemeyi bir araya getirdiği metodolojide, eşsiz toprakların benzersiz toprak oluşturan faktör kümelerinin ürünü olduğu kavramsal modeline dayanarak, toprak oluşturan faktörleri temsil etmek için sayısal yükseklik modellerinden (SYM) elde edilen topoğrafik veriler ve Landsat 5 spektral verilerini kullanarak, ISODATA kümeleme algoritması ile denetimsiz sınıflandırma gerçekleştirmişlerdir. Bir deneme yanılma yaklaşımında çeşitli veri katmanları yığınları ve sınıf sayıları (6–20) kullanılmış, sınıflandırmalar hava fotoğrafından yorumlanan arazi üzerindeki harita birimlerini temsil edebilecek desenler üretene kadar bu süreci devam ettirmişlerdir. Son denetimsiz sınıflandırma ürünü olarak üç bantlı toprak zenginleştirme oranları, eğim

ve fraksiyonel bitki örtüsü kullanan 12 sınıflı bir görüntü seçilmiştir. Bu harita, ilk saha örnekleme ve sonraki sınıflandırmalar için bir planlama aracı olarak kullanılmıştır.

Triantafilis vd. (2009), proksimal algılama, elektromanyetik indüksiyon (EM) ve uzaktan algılanan veriler gibi yardımcı bilgileri kullanarak, bulanık k-ortalama (FKM) algoritmasını toprak yönetimi sınıflarını tanımlamak amaçlı uygulamışlardır. Çalışma sonucunda EM38 ve EM31'in, doku ve mineralojiye dayalı olarak Vertosol ve Dermosollerin ayırımına en çok katkıda bulunduğu bildirilmiş, kırmızı ve yeşil dijital numaralarının, organik madde içeriğine dayalı Vertosollerin ayırımına katkıda bulunduğu sonucuna varmışlardır.

Genel olarak, bir arazideki toprak ilişkileri ne kadar karmaşıksa, tüm özellik alanını sistematik olarak haritalamak için o kadar fazla örnek gerekir. Mekânsal varyasyon alt bölge düzeyinde farklılık gösteriyorsa, bölgeler ayrı ayrı modellenmelidir. Schmidt vd. (2010), haritalama birimlerinin yerel mekânsal frekans dağılımına dayalı olarak kategorik mekânsal veri kümelerini bölümlere ayırmak için yarı otomatik bir yaklaşım sundukları çalışmasında, düzgünleştirilmiş sınırlara sahip homojenize ve keskin sınır çizgileriyle bölümlenmemiş segmentler sağlamak amacıyla k ortalamaları algoritmasını kullanmışlardır. Yükseklik, eğrilik gibi arazi parametreleri ve jeoloji haritalarının çevresel değişken olarak kullanıldığı bu çalışmada 10 farklı toprak sınıfı oluşturulmuştur. Özellik alanı açısından, bu 10 farklı sınıfın, alan bütünlüğüne göre daha yüksek bir homojenlik gösterdiğini bildirmektedirler.

Toprak oluşturan faktörleri temsil eden mekânsal veriler, yaygın bir şekilde elde edilebilir hale gelmektedir. Browning ve Duniway (2011), özellikle uzak ve geniş kurak alanlarda sahaya dayalı eğitim verilerinin kısıtlayıcı bir faktör olduğu Landsat 7 ETM+ görüntüleri ve yüksek çözünürlüklü (5 m) arazi verileriyle toprakları haritalamak için, saha eğitim verilerine dayanmayan, giriş veri katmanlarının istatistiksel özelliklerine dayalı bir yöntem geliştirdikleri çalışmalarında, yorumlamayı kolaylaştırmak için haritalanan toprak sınıflarının türlerini ve özelliklerini karakterize etmişlerdir. Çalışma alanı içinde meydana gelen istatistiksel ve spektral olarak ayrılabilir toprak sınıflarının sayısını belirlemek ve farklı toprak sınıfları arasında en iyi ayrım yapan veri katmanları alt kümesini belirlemek amacıyla yürütülen bu

çalışmada, sonuç olarak yalnızca yorumlanabilir bir toprak sınıfları haritası sağlamanın yanında, aynı zamanda tanımlanmış benzersiz sınıfların, araziye diğer enterpolasyon türleri (örneğin, kriging) için katmanlara ayırmak için etkili bir yöntem olabileceğini bildirmişlerdir. Çalışmada haritalanan toprak sınıflarının saha değerlendirmesi sonucu, bu yaklaşımın, görüntü sınıflandırmasını yönlendirmek için alan örnekleri olmadan bir arazi içindeki toprak türlerinin dağılımını doğru bir şekilde haritalayabileceğini göstermiş, görünür spektrumdaki bantlarının nispeten katkısının daha az olduğunu ve topoğrafik ıslaklık indeksinin toprak sınıflarını ayırt etmede en etkin rol oynadığını bildirmişlerdir. Sığ olan kalsik ve petrokalsik horizonlar, toprak yüzeyinin yakınında ise farklı yansıma seviyeleri gösterebilecektir. Yansıyan toprak özelliklerini en üst düzeye çıkarmak için ortalamanın altında bir yağış ve bitkisiz dönemde elde edilen bir Landsat görüntüsünün seçilmesi, genellikle yüzeye yakın toprak nemine duyarlı olan kısa dalga kızılötesi bantlarının yararını azaltmış olabileceğini bildirmişlerdir.

Guo vd. (2013), tuzluluk yönetimi sınıflarını belirlemek için sayısal toprak haritalama yöntemlerinin uygulanması amacıyla yaptıkları çalışmada, normalize fark bitki indeksi (NDVI) kullanarak üç tuzluluk yönetim bölgesini belirlemek için bulanık k ortalama algoritmasını kullanmışlar, uzaktan algılanan yardımcı verilerin toprak tuzluluk yönetim bölgelerini tanımlamak için bir araç olarak kullanılabileceğini bildirmişlerdir.

Huang vd. (2014), Kıyı bölgelerdeki asit sülfat toprakları dijital olarak haritalamak amacıyla yaptığı çalışmada, yüksek çözünürlüklü bir sayısal yükseklik modeli ile birlikte yatay ve dikey modlarda toprak elektrik iletkenliğinin EM38 ölçümlerini yardımcı veriler olarak belirlemişler, kümelemek için bulanık k-ortalama algoritmasını çalıştırmışlardır. Nihai haritanın, geleneksel toprak haritalama kullanılarak oluşturulan önceden tanımlanmış toprak-arazi birimleri ile tutarlı olduğunu, sayısal toprak haritalama yaklaşımının, geleneksel yaklaşım kullanılarak önceden haritalanmış asit sülfat toprakların sınırlarını iyileştirmek veya haritalanmamış bulunan asit sülfat toprak alanlarını belirlemek için uygun olduğunu bildirmişlerdir.

Zare vd. (2016), Uzaktan ve proksimal olarak algılanan verileri sayısal olarak kümelendirerek bölge ölçeğinde toprak birimlerini tanımlamak amacıyla yaptıkları çalışmada, bulanık k ortalama algoritmasını kullanmışlardır. Çalışma sonucunda uzak

γ -ışını spektrometresi (K, U, Th ve TC) ve proksimal toprak elektrik iletkenliği EC_a (EM38_h ve EM38_v) verileriyle toprak arazi birimlerini objektif olarak ve bölge düzeyinde belirleme potansiyeli gösterdiği sonucuna varmışlardır. K=4 değeri alındığında, oluşan 4 sınıflı haritanın geleneksel yöntemler kullanılarak önceden tanımlanmış toprak peyzaj birimlerini genel olarak temsil ettiğini bildirmişlerdir.

Geleneksel toprak haritalama, toprak profillerini önceden tanımlanmış sınıflandırma sistemlerine göre sınıflandırmak için saha morfolojik gözlemlerini kullanır ve hava fotoğraflarına ve araştırmacının deneyimine dayalı bir harita yapmak için sınıflandırılmış toprakları tahmin eder. Bu yaklaşımın eleştirisi, etütçünün öznelliğinin tekrarlanamayan haritalara yol açmasıdır. Hesaplama ve istatistiksel analizdeki gelişmeler ve yardımcı verilerin artan kullanılabilirliği sayısal toprak haritalama (STH) olarak adlandırılan bir alternatif sağlamıştır. Zare vd. (2017), Avustralya, New South Wales bölgesinin merkezinde bulunan iki tarımsal üretim alanında, geleneksel yaklaşıma göre tanımlanan toprak profili sınıflarının da bir STH yaklaşımı kullanılarak haritalanmasına yönelik yaptıkları çalışmada, bulanık k ortalama algoritmasını kullanmışlardır. Üretilen STH haritaları K = 3, 6 ve 8 sınıf sayılarında geleneksel yaklaşım kullanılarak tanımlanan toprak haritalama birimlerini yansıttığını, K = 8 olduğunda STH haritalarının arazide tanımlanan toprak profili sınıflarını yansıttığını bildirmişlerdir.

Toprak haritalama ünitelerinde eğitim verisi olarak zemin profillerinin bulunmadığı durumlarda, K-ortalama ve bulanık k ortalama kümeleme yaklaşımları gibi denetimsiz sınıflandırmalar uygulanabilir. Bulanık k ortalama ve k ortalama kümeleme yaklaşımları, çevresel değişkenlerden kümeler oluşturmak için kullanılabilir ve ardından her kümeye harita lejantının toprak sınıfları atanabilir. Zeraatpisheh vd. (2019), İran'ın Borujen bölgesinde hem büyük grup hem de alt grup taksonomik seviyeleri için eski bir 1:1 000 000 ölçekli toprak haritasını ayrıştırmak amacıyla yaptığı çalışmada, bulanık k ortalama yöntemini kullanmıştır. Sırasıyla alt grup ve büyük grup seviyelerinde 7 ve 6 toprak sınıfının bulunduğu çalışma alanında, denetimsiz sınıflandırma (Bulanık k-ortalama ve K-ortalama kümeleme yaklaşımları) ile elde edilen kümeler, uzman bilgisinin kontrolünde, peyzajdaki toprak tipi dağılımına göre harita açıklamasındaki her toprak sınıfına atanmıştır. Ayrıştırma yaklaşımının performansını karşılaştırmak için, k ortalama algoritması ile üretilmiş ve

sınıf etiketleri belirlenmiş olan ayrıştırılmış harita, 1:1 000 000 ölçeğindeki eski toprak haritası ve USDA toprak taksonomisine göre (USDA-Soil Taxonomy, 1999) sınıflandırılmış 125 toprak profili kullanılmıştır. Sonuçlar, ayrıştırılmış haritaların genel doğruluğunun alt grup ve büyük grup seviyelerinde sırasıyla %15 ve %31 olduğunu göstermiştir. 1:1 000 000 ölçeğindeki eski toprak haritası için genel doğruluk sırasıyla %52 ve %65'dir.

Ngunjiri vd. (2019), Sınırlı veriye sahip çalışma alanının mevcut toprak haritalarını geliştirmek amacıyla Kenya'da yürüttükleri çalışmada, çok çözünürlüklü vadi dibi düzlük indeksi (MrVBF), çok çözünürlüklü sırt üstü düzlük indeksi (MrRTF), topoğrafik konum indeksi (TPI) ve profil eğriliği gibi çevresel değişkenlerle ve k-ortalama kümeleme ve bulanık mantık toprak haritalama yaklaşımlarını kullanarak toprak haritalarını ayrıştırmışlardır. 34 saha gözlemi, toprak tipi haritalarının daha sonra doğrulanması için Dünya referans sistemi (WRB) ve USDA Toprak taksonomisine göre sınıflandırılmıştır. Bulanık mantık algoritması ile üretilen haritanın genel doğruluğu, %76, K ortalama algoritması ile üretilen haritanın genel doğruluğu %68'dir. Ayrıca bulanık mantık için kappa katsayısı %68 K ortalama algoritmasının ise %59 olarak belirlenmiştir. Bulanık mantığın K ortalama algoritmasından daha iyi doğruluk ürettiği Nitisoller dışında, her iki yöntemi de tüm toprak türleri için benzer kullanıcı ve üretici doğruluğuna sahip olduğu bildirilmiş ve genel olarak hem k ortalama hem de bulanık mantık ile haritalamanın iyi performans gösterdiğini ve bulanık mantık haritalamanın biraz daha iyi performans gösterdiğini ifade etmişlerdir.

Dotto vd. (2020), toprakları kantitatif bir şekilde sınıflandırmak amacıyla spektral, iklim ve arazi değişkenlerine dayalı bir toprak gruplama sistemi geliştirmek amacıyla yaptıkları çalışmada, pedologların toprak-çevre etkileşimleri hakkındaki bilgisini modelleyebilmek için, spektral veriler, iklim ve arazi değişkenlerini kullanmış, Dünya referans (WRB) sisteminin toprak sınıfları, belirtilen üç değişken kullanılarak k ortalama algoritması ile tahmin edilmiştir. Optimum küme sayısı 8 olarak belirlenmiş ve bu grupları geleneksel taksonomik yöntemle değil, belirtilen değişkenlerle ifade edilen benzer özelliklere sahip alanları gruplayarak oluşturmuşlardır "Toprak çevre gruplamaları" (SEG) olarak adlandırılan SEG sistemi, yalnızca toprağı değil, aynı

zamanda çevresel değişkenleri de kullanarak eşdeğer özelliklere sahip grupların tanımlanmasını kolaylaştırdığını bildirmişlerdir.

Minai vd. (2020), Kenya'nın Busia Bölgesinde, 1:100 000 keşif toprak haritasının toprak arazi kurallarına dayalı bir yaklaşım kullanılarak ayrıştırılması amacıyla yaptıkları çalışmada, k ortalama algoritmasını kullanmışlar, ayrıştırılmış toprak sınıfı haritasının genel doğruluğunun %58, kappa katsayısının %54 olduğunu bildirmişlerdir.

2.4.3. Bilgi temelli sınıflandırma

Bilgi temelli sınıflandırma, bir uzmanın bilgisini bilgisayardaki kurallar ve verileri temsil etmek için uzman sistemler kullanır (Jensen, 2005). Sadece toprak sınıflarını tahmin etmek için geçerli değildir, aynı zamanda bir toprak bilimcisinin toprak-arazi ilişkileri hakkındaki bilgilerini belgelemek için de çok yararlıdır (Zhu vd., 2001). Kural seti, değişken verileri ve uzmanın toprak-arazi ilişkileri hakkındaki bilgileri ve verilerle nasıl ifade edildikleri kullanılarak oluşturulur.

Vargas ve Alim (2007), SWALIM tarafından faaliyetlerinin arazi uygunluğu ve arazi bozulması değerlendirme bileşenlerine birincil girdi olarak toprağın mekânsal değişkenliğini haritalamak için modern ve geleneksel yaklaşımların bir kombinasyonu kullanılarak bir toprak araştırması gerçekleştirilmesi kapsamında, Toprak nem rejimi, litoloji, arazi kullanımı, arazi örtüsü, jeomorfoloji ve eğim sınıfları katmanlarının dijital ortama entegre edilerek, ILWIS 3.3 yazılımında modüller aracılığı ile karar ağaçları, harita hesaplama formülleri kullanılarak bir mekânsal analiz sürecinde programın imkan verdiği yazılım dilince yazılmıştır (SQL, Python vb.). Çalışmada doğrulama için yersel doğrulama verisi olmaması sebebi ile doğrulama uzman etütçülerin arazideki bilgilerine dayanmaktadır.

2.5. Toprak Özelliklerini Tahmin Etmeye Yönelik Çalışmalar

Regresyon ve interpolasyon yöntemleri, ayrık sınıflardan ziyade sürekli değerleri öngörmektedir. Sürekli bir toprak özelliğinin tahmini için regresyon yöntemleri kullanılır. Bu geniş grup içinde, tahmine dayalı modeller, modelin türüne göre daha da

bölünebilmektedir. Doğrusal, doğrusal olmayan veya karar ağaçları veya kural tabanlı olacak şekilde farklı modelleme yaklaşımları mevcuttur. Doğrusal yöntemlerin örnekleri basit doğrusal regresyon ve diskriminant analizidir. Doğrusal olmayan yöntemlerin örnekleri yapay sinir ağları ve rastgele orman algoritmalarıdır.

Enterpolasyon yöntemleri, bir hedef değişkenin öznitelik değerlerinin mekânsal olarak ilişkili olması (mekânsal otokorelasyon) ve daha yakın olan konumların, konumların daha uzak olduğundan daha fazla öznitelik benzerlik değerlerine sahip olduğu durumları tanımlamaktadır (Tobler, 1970). Jeostatistiksel yaklaşımlar, matematiksel fonksiyonlardan ziyade istatistiksel fonksiyonlara dayanan enterpolasyon biçimleridir. Regresyon yaklaşımları, toprak gözlemleri ve bir dizi çevresel değişken arasındaki ilişkiyi modellemek için bazı istatistiksel fonksiyonları kullanmaktadır.

Coğrafi olayların doğası gereği heterojen olduğu düşünüldüğünde, bu ilişkilerin statik kalması veya mekânda aynı kalması zordur. Bu, özellikle geniş ve karmaşık coğrafi alanlar da daha geçerli bir durumdur. Coğrafi olayların mekânsal heterojenliği, coğrafi araştırmaların başlıca konularından biri olmuştur (Zhu vd., 2018).

Pek çok potansiyel tahmin modeli mevcut olmasına rağmen, herhangi bir sayısal toprak haritalama projesi için her zaman en doğru tahminleri üretebilecek bir model bulmak zordur. Bunun nedeni, model tahmin yeteneğinin, bireysel veri kümelerinin yapısına ve ortak değişken seçimi için kullanılan yöntemlere bağlı olmasıdır (Brown vd., 2017).

En iyi yaklaşım, birkaç tahmin modeli uygulamak ve en doğru tahmini üreten modeli seçmektir. Kişi, karmaşık bir modelle (örneğin, rastgele ormanlar veya sinir ağları) başlayabilir, daha sonra daha basit modellerle (örneğin, doğrusal regresyon veya sınıflandırma ağaçları) karşılaştırabilir. Daha basit modelin doğruluğu daha karmaşık modelle karşılaştırılabilirse, daha basit model seçilebilir. Basit modeller yorumlama kolaylığı için tercih edilmektedir.

Toprak özelliklerinin arazideki dağılımı, çeşitli arazi yönetim uygulamaları için gereklidir. Farklı çalışmalarda farklı sayısal toprak haritalama yaklaşımlarının (doğrusal ve doğrusal olmayan modeller), toprak organik karbonu, kil içeriği ve

kalsiyum karbonat eşdeğeri dahil olmak üzere bazı üst toprak özelliklerini tahmin etme yeteneğini ele almaktadır.

Gobin vd. (2001), Nijerya'nın güneydoğusundaki bir havzada sayısal yükseklik modelinden üretilen çevresel değişkenleri kullanarak, çoklu doğrusal regresyon modeli ile kil, silt ve kum içeriklerini belirlemişlerdir. Kil için R^2 : 0.41, RMSE: %0.108, silt için R^2 : 0.75, RMSE: %0.143, kum için R^2 : 0.55, RMSE: %0.249 olarak belirlemişlerdir. Bileşik topoğrafik indeks ve eğim gradyanı, daha küçük partikül boyutları (kil ve silt) ile iyi ilişki gösterirken, daha büyük partikül fraksiyonlarının, akış gücü indeksi ile daha iyi ilişkili olduğunu bildirmişlerdir.

Sürdürülebilir arazi yönetimi ve arazi kullanım planlaması için fiziksel ve kimyasal toprak özelliklerinin mekânsal dağılımı hakkında güvenilir bilgi gerekmektedir. Sumfleth vd. (2008), Çin'in Jiangxi eyaletinin doğu kesiminde 10 km²'lik alanda, arazi verileri ve uydu bilgilerini kullanarak toplam karbon, azot ve üst toprak silt, kum, kil içeriği dağılımının tahmini amacıyla yaptıkları çalışmada, NDVI'nin karbon ve azot dağılımının mekânsal durumunu dolaylı olarak yansıttığını bildirmişler, topoğrafik değişkenlerinin ve NDVI'nin birlikte kullanımının, toplam C içeriğinin varyasyonunun %41, toplam N içeriği varyasyonunun %36'sını ve silt içeriği varyasyonunun % 29'unu açıkladığını bildirmişlerdir.

Başayığı vd. (2009), ASTER-TERRA uydusunun görünür bölge, kısa dalga kızılötesi ve termal kızılötesi bantlarından elde edilen spektral yansıma değerleri ile toprak özellikleri arasındaki ilişkileri belirlemek üzere yaptıkları çalışmada, silt içeriği ile termal kızılötesi 3 bandı arasında önemli bir ilişki belirlemişlerdir. Benzer şekilde organik madde ile görünür bölge 2 bandı arasında da yüksek bir korelasyon belirlenmiştir.

Ließ vd. (2012), dijital bir yükseklik modelinden türetilen arazi özelliklerini, iki parçacık boyutu dağılımı belirleme yöntemi ile modelleme sonuçlarını karşılaştırmış, kum için mekânsal değişkenliğinin %30'unu, kil için mekânsal değişkenliğinin %43'ünü, silt için mekânsal değişkenliğinin %26'sını açıkladığını bildirmişlerdir. Çalışmada rastgele orman algoritmasının düşük performansı, veri setinin küçük boyutuna bağlanmıştır. Nijerya'da yapılan bir çalışmada Akpa ve vd. (2014), Rastgele

orman için mekânsal değişkenliği açıklama yüzdesinin kum için %48-49, silt için %26-27 ve üst toprak tabakasında kil için %53-56 olduğunu bildirmiştir.

Gardi ve Yigini (2012), Avrupa’da sayısal toprak haritalama yaklaşımı kullanılarak toprak pH'nın haritalanması amacıyla yürüttükleri çalışmada, üst toprak pH'ı (CaCl_2) 30 000'den fazla nokta ve 27 ortak değişken ile modellenmiştir. Model sonuçları olarak R^2 değeri 0.46, RMSE 0.18 olarak belirlenmiştir.

Hengl vd. (2015), Afrika Toprak Bilgi Hizmeti (AfSIS) projesi kapsamında Afrika kıtası ölçeğinde yaptığı çalışmada, toprak fiziksel ve kimyasal özelliklerini 250 metre mekânsal çözünürlükte haritalamak için çoklu doğrusal regresyon ve rastgele orman modellerini kullanmıştır. Tüm özellikler için, rastgele orman modelinin, doğrusal regresyon modelinden daha doğru tahminler verdiğini bildirmişlerdir. Çoklu doğrusal regresyon modeli sonuçlarına göre, toprak organik karbon içeriği tahmin modelinde RMSE: 12.2 g kg^{-1} , suda belirlenen pH için RMSE: 0.88, katyon değişim kapasitesi için RMSE: $11.0 \text{ cmol kg}^{-1}$, değişebilir sodyum için RMSE: $15.5 \text{ cmol kg}^{-1}$ olarak belirlenmiştir.

Samuel-Rosa vd. (2015), Brezilya’nın güneyinde 2000 ha alanda yaptıkları çalışmada, toprak sınıf haritaları, sayısal yükseklik modelinden üretilen çevresel değişkenler, jeolojik veriler, arazi kullanımı ve uydu görüntülerinden üretilen çevresel değişkenleri kullanarak, üst toprağın kil içeriğini, organik karbon içeriğini ve etkili katyon değişim kapasitesini çoklu regresyon modeli ile tahminine yönelik yaptıkları çalışmada, kil için RMSE: 68.1 g kg^{-1} , organik karbon için RMSE: 16.9 g kg^{-1} , etkili katyon değişim kapasitesi için RMSE: $97.9 \text{ mmol kg}^{-1}$ olarak belirlenmiştir. Mekânsal çözünürlüğü daha yüksek çevresel değişkenlerin kullanımının, doğrusal tahmin modellerinin tahmin doğruluğunda az artışa neden olduğunu, model doğruluğunun getirisinin mekânsal çözünürlüğün getirebileceği ekstra maliyetlerden daha ağır basmayabileceğini bildirmişlerdir.

Mosleh vd. (2016), farklı sayısal toprak haritalama (STH) yaklaşımlarının, İran'ın Sahrekord ovasındaki bazı fiziksel ve kimyasal üst toprak özelliklerini tahmin etme yeteneğini belirlemek üzere yaptıkları çalışmada, parçacık boyutu dağılımı, elektriksel iletkenlik (EC), pH, organik karbon ve kalsiyum karbonat eşdeğeri özellikleri ile

çalışmışlardır. Toprak özellikleri ile çevresel değişkenler arasındaki ilişkiyi belirlemek ve tahmin etmek için çoklu doğrusal regresyon modelini de kullanmışlardır. pH için R^2 değeri 0.03, RMSE 0.15, elektriksel iletkenlik (EC) için R^2 değeri 0.11, RMSE 0.19 dS m⁻¹, organik karbon (OC) için R^2 değeri 0.26, RMSE %0.87, kalsiyum karbonat eşdeğeri için R^2 değeri 0.06, RMSE %11.5, kil için R^2 değeri 0.24, RMSE %8.7, Silt için R^2 değeri 0.1, RMSE %12.5, Kum için R^2 değeri 0.05, RMSE %12.8 olarak belirlenmiştir.

Da Silva Chagas vd. (2016), Brezilya'nın kuzeyinde yarı kurak bir bölgede 35 000 hektarlık alanda rastgele orman ve çoklu doğrusal regresyon kullanarak toprak yüzey tekstürünün mekânsal tahminini yaptıkları çalışmada, Landsat 5 TM verisine ait 1, 2, 3, 4, 5, 7 bantları, normalize fark bitki indeksi ve üst toprak tane büyüklük indeksi değişkenlerini kullanarak, toprak kil, silt ve kum içeriklerini tahmin etmişlerdir. Rastgele orman algoritmasının kum ve kil içeriklerinin mekânsal değişkenliğinin sırasıyla %63 ve %56'sını açıkladığını, çoklu doğrusal regresyon ise silt mekânsal varyasyonunun %30'unu açıkladığını bildirmiştir. Çoklu doğrusal regresyon ile kil için R^2 : 0.53, RMSE: 93.28 g kg⁻¹, silt için R^2 : 0.20, RMSE: 44.50 g kg⁻¹, kum için R^2 : 0.49, RMSE: 75.17 g kg⁻¹ olarak belirlenmiştir.

Türkiye'de toprak karbon stokunun öncelikle tespitine ve artırılmasına yönelik çalışmalar yapmak hedefi doğrultusunda Çölleşme ve Erozyonla Mücadele Genel Müdürlüğü ve TÜBİTAK-BİLGEM-YTE iş birliği ile birlikte Toprak Organik Karbonu Projesi yürütülmüştür (ÇEM, 2018; TÜBİTAK BİLGEM YTE, 2018). Türkiye topraklarında bulunan organik karbon stok durumunun belirlenmesi öncelikli amacıyla yapılan bu çalışmada, 0-30 cm toprak derinliğinde alınmış koordinat bilgilerine ulaşılabilen ve veri kalitesi kontrol edilebilen toplam 19310 örnek kullanılmıştır. Hacim ağırlığı verisi olmayan veri setleri için pedotransfer yöntemleri ile hacim ağırlıkları tahmin edilen metodoloji sonucunda, toprak organik karbon stokları 0-30 cm derinlik için ton karbon ha⁻¹ olarak hesaplanmıştır. Modelleme tekniği olarak rastgele orman algoritmasının kullanıldığı çalışmada, toprak organik karbon stok durumunu tahmin etmek için örnekleme noktaları katmanı, eğim yüksekliği, vadi derinliği, arazi pürüzlülük indisi, maksimum sıcaklık, sıcaklık mevsimselliği indisi, güneş ışıınımı, Conrad karasallık indisi, yağış, en nemli çeyreğin yağış miktarı, en soğuk çeyreğin yağış miktarı, potansiyel evapotranspirasyon, net birincil verimlilik,

net birincil verimlilik (Temmuz), ağaç kapalılık yüzdesi, yüzey yansıması indisi gibi çevresel değişkenleri veri yığını ile karşılaştırılmış, modelleme amaçlı kullanılacak veri matrisi oluşturulmuştur. Nihai olarak test veri seti korelasyon değerini 0.65 olarak belirledikleri çalışma sonucunda üretilen haritanın Türkiye’de farklı kurumlar için altlık temel veri kaynağı olabileceğini bildirmişlerdir (ÇEM, 2018).

Zeraatpisheh vd. (2019), yarı kurak bir bölgede çoklu doğrusal regresyon kullanılarak toprak özelliklerinin dijital haritalanması amacıyla yürüttüğü çalışmada, toprak organik karbonu için, eğitim seti R^2 değeri 0.53, test seti için 0.50, RMSE değerlerini ortalama %0.35 olarak belirlemişlerdir. Kalsiyum karbonat eşdeğeri için, eğitim seti R^2 değeri 0.33, test seti için 0.28, sırasıyla RMSE değerlerini %9.21 ve %9.55 olarak belirlemişlerdir.

Zeraatpisheh vd. (2019), İran'ın yarı kurak bir bölgesinde çok değişkenli istatistiksel analizlerin, hangi toprak özelliklerinin belirli çevresel özelliklerle koşullandırılmış net bir mekânsal modeli izlediğini ayırt etme yeteneğini araştırdıkları çalışmada, dijital yükseklik modelinden (SYM) on topoğrafik öznitelik ve Landsat 7 ETM+ uydusundan beş uzaktan algılama değişkenini kullanmışlardır. Toprak özellikleri, uzaktan algılama verilerini ve topoğrafik nitelikleri kullanan temel bileşen analizinin sonuçlarına göre, toprak özelliklerinin toplam değişkenliğinin % 73.3'ünü açıklayan beş ana bileşeni tanımlanmıştır. Yamaç morfolojisi ve tüm uzaktan algılama değişkenleri gibi çevresel faktörlerin, toprak organik karbonu değişkenliğini büyük ölçüde açıklayabileceğini, ancak toprak dokusu ve kalsiyum karbonat eşdeğeri içerikleri için çevresel değişkenlerle önemli bir korelasyon bulunmadığını bildirmişlerdir.

De Castro Padilha vd. (2020), toprak organik karbonunu haritalamak için Landsat verileri ve toprak kil içeriğini kullandıkları çalışmalarında, eğitim seti R^2 değeri 0.79, test seti için 0.81, RMSE değerleri 0.14 g kg^{-1} olarak belirlenmiştir.

Poppiel vd. (2021), Açık veri ve bulut teknolojisi aracılığıyla orta doğu topraklarının özelliklerini yüksek çözünürlüklü haritalamak amacıyla yaptıkları çalışmada, 3 338 000 km^2 'ye yakın bir alanını haritalamak için 5000'den fazla sahadan elde edilen üst toprak verilerini (0-20 cm) kullanarak, uzaktan algılama verileri ve rastgele orman (RF) algoritması ile üst toprakta kil, silt, kum, organik karbon, pH ve $\% \text{CaCO}_3$

içeriklerinin haritalamasını yapmışlardır. Rastgele orman regresyon modellerini R yazılımında eğitilmesi ve Google earth engine içinde üst toprak özellikleri ve ilişkili belirsizlikler için mekânsal tahminler yapmak için en uygun modelleri (ortalama karekök hatasına göre) kullanarak yürüttükleri çalışmada, tüm ortak değişkenlerin göreceli öneminin, %4 ila %98 arasında değiştiğini, yıllık yağış, yıllık sıcaklık aralığı ve yükseklik değişkenlerinin en önemli olduklarını bildirmişlerdir Genel olarak, rastgele orman (RF) tarafından eğitilen tahmin modelleri, üst toprak özelliklerinde bulunan varyasyonun yaklaşık %40-66'sını açıkladığını bildirmişlerdir.



3. MATERYAL VE YÖNTEM

3.1. Materyal

Çalışma Atabey Ovasında yürütülmüştür. Çalışmada alana ait Akgül vd. (2001), tarafından hazırlanmış detaylı toprak etüt raporu ve 1: 25000 ölçekli detaylı temel toprak haritası altlık materyal olarak kullanılmıştır. Ayrıca tez çalışmasının arazi çalışmaları esnasında alınan toprak örneklerinde yapılan analizler veri setini oluşturmada kullanılmıştır.

Rapora göre; çalışma alanı toprakları, 7 farklı fizyografya üzerinde yer almaktadır. Alanda bulunan fizyografik üniteler, yüksek tepelik ve sırtlar, kolüvyal etekler, alüvyal yelpazeler, yaşlı dere yatakları, bajadalar, taban arazileri ve genç dere yataklarıdır.

Atabey ovası topraklarında 20 profil açıldığı, 20 adet pedon tanımlandığı ve sınıflandırıldığı görülmektedir (Akgül vd., 2001). Soil Survey Staff'a (USDA-NRCS, 1999) göre tanımlanan bu serilerden Pembeli, Kırlar, Onaç ve Akçay serileri Entisol ordosu; Yakabağları, Bayat, Yeşilova, Büyükgökçeli, Çayakıntısı, Kuleönü, İslamköy, Yenibağlar, Pazararkası, Kuştepe, Kırbağları ve Hıdırlık serileri İnseptisol ordosu; Serenli ve Orkav serileri Mollisol ordosu, Karaağaçlar ve Dikilitaş serileri ise Vertisol ordosunda yer almıştır. Serilerin FAO Dünya Referans sistemine (FAO, 1998) göre sınıflandırılmasında ise, Serenli, Orkav, Pembeli, Kırlar, Onaç, Akçay Serileri Fluvisol grubu; Yakabağları, Kırbağları, İslamköy, Pazararkası ve Hıdırlık serileri Calcisol Grubu; Bayat, Kuştepe, Yeşilova, Büyükgökçeli, Çayakıntısı, Kuleönü ve Yeni bağlar serileri Cambisol grubu, Karaağaçlar ve Dikilitaş serileri ise Vertisol grubu içerisinde yer almıştır.


Sayısal toprak haritalama çalışmalarında farklı metodolojilerin çalışıldığı bu bölgenin toprak serilerinin Toprak Taksonomisi ve FAO Dünya Referans sistemine göre sınıflandırılması Çizelge 3.1'de verilmiştir. Buna göre çalışma alanı topraklarının %14.45'i Entisol, %52.46'sı İnseptisol, %20.11'i Mollisol ve %12.06'sı Vertisol ordosunda yer almıştır.

Çalışma alanında veriler sağlandıktan sonra UTM Kuzey 36. Zona göre sayısalılaştırılmış ve çalışmalarda dijital olarak kullanılabilecek formatlara getirilmiştir (Şekil 2.1).

Şekil 2.1’de Çalışma alanında kullanılacak Toprak Taksonomisi ve FAO Dünya Referans sistemine göre mevcut haritaları bulunmaktadır.

Çizelge 3.1. Çalışma alanı topraklarının sınıflandırılması



Toprak Taksonomisine göre sınıflama					FAO (2.Seviye)
ORDO	ALT ORDO	BÜYÜK GRUP	ALT GRUP	SERİ	Büyük Toprak Gr.
Entisol	Fluvent	Xerofluvent	Typic Xerofluvent	Pembeli	Calcaric Fluvisol
				Kırlar	Calcaric Fluvisol
				Onaç	Calcaric Fluvisol
				Akçay	Calcaric Fluvisol
İnseptisol	Xerept	Calcixerept	Petrocalcic Calcixerept	Yakabağları	Petric Calsisol
				Kırbağları	Petric Calsisol
				Hıdırlık	Petric Calsisol
			Typic Calcixerept	İslamköy	Haplic Calcisol
				Pazararkası	Haplic Calcisol
		Haploxerept	Vertic Haploxerept	Bayat	Vertic Cambisol
			Calcic Haploxerept	Kuştepesi	Eutric Cambisol
			Fluventic Haploxerept	Yeşilova	Eutric Cambisol
				Büyükgökçeli	Eutric Cambisol
			Typic Haploxerept	Çayakıntısı	Eutric Cambisol
				Kuleönü	Eutric Cambisol
				Yenibağlar	Chromic Cambisol
Mollisol	Xeroll	Haploxeroll	Typic Haploxerol	Serenli	Mollic Fluvisol
			Vertic Haploxerol	Orkav	Mollic Fluvisol
Vertisol	Xerert	Haploxerert	Udic Haploxerert	Diklitaş	Eutric Vertisol
				Karaağaçlar	Eutric Vertisol



Şekil 3.1. Çalışma alanı mevcut toprak haritası sınıflandırma seviyeleri

3.1.1. Çalışma alanı

Çalışma alanı Türkiye'nin Batı Akdeniz bölgesi içerisinde yer almaktadır. Isparta il sınırları içerisinde yer almaktadır. Çalışma alanı UTM Kuzey 36. Zona göre 419200-420400 kuzey 288000-304000 doğu koordinatları arasında yer alan yaklaşık 100 km²'lik alanı kapsamaktadır. Çalışma alanı yer buldur haritası Şekil 3.2'de verilmiştir. Java newhall simülasyon modeline göre çalışma alanı Mesic toprak sıcaklık rejimine, Xeric toprak nem rejimine sahiptir (Van Wambeke, 2000) (Şekil 3.3). Çalışma alanı temel olarak Holosen yaşlı birikintilerden oluşmaktadır (MTA, 2021). Bu yapı jeolojik süreç içerisinde ovayı çevreleyen Mesozoik-Tersiyer kireçtaşlarından su, yerçekimi veya her ikisinin birlikte etkilemesi ile taşınan materyalden oluşmuştur. Bu materyal kapalı çanak biçiminde bulunan Atabey ovasını çevreleyen kireç taşlarının eteklerinde kaba, ovanın ortalarında ince yapıli birikimler oluşturmuştur (Akgül vd., 2001).



3.1.2. Kullanılan çevresel değişkenler

Sayısal toprak haritalamada kullanılan en yaygın çevresel değişkenler şunlardır: (1) Arazi yüzeyinin ham spektral ve çok spektrumlu görüntüleri, (2) Sayısal yükseklik modeli türevleri, (3) İklim verileri, (4) Bitki örtüsü ve toprak örtüsü bazlı ortak değişkenler ve (5) Arazi kullanım bilgileridir (McBratney vd., 2011; White, 2013; Hengl ve Macmillan, 2019).

Çalıştığımız alanında birden fazla meteoroloji istasyonu olmaması nedeniyle ve iklimin mekânsal varyasyonu çok az değişmesi nedeniyle (Cole vd., 2007; Howell vd., 2008; Silva vd., 2019) iklim (c) çevresel değişkeni kullanılmamıştır. Nitekim farklı arazilerde farklı toprak oluşturan faktörlerin değişen derecelerde etkisi nedeniyle, dahil edilecek kesin çevresel değişkenler dizisi bulunmadığı belirtilmektedir (Zhu vd., 2001). Bu çalışmada topoğrafya, ana materyal ve organizmalar faktörleri değerlendirilmiş, bu faktörlere ait çevresel değişkenler üretilmiş ve ilgili yaklaşımlarda tahmin edici değişken olarak kullanılmıştır.

3.1.2.1. Topoğrafik çevresel değişkenler

Arazi özellikleri genel olarak iki kategoriye ayrılabilir: (1) doğrudan bir SYM'den hesaplanan birincil özellikler ve (2) birincil özelliklerin kombinasyonları ve türevi olan özellikler (Moore vd., 1991). Çalışma alanına ait Sayısal yükseklik modeli ASTER-GDEM (NASA, 2019) "<https://search.earthdata.nasa.gov>" adresinden indirilmiş ve ArcGIS-Arctoolbox-Raster processing toolset-Resample aracı kullanılarak 30 metre çözünürlüğe getirilmiştir. Bu veri setinden topoğrafyaya ait çevresel değişkenler, ArcGIS (ESRI, 2010) yazılımı kullanılarak hesaplanmıştır. Sayısal Yükseklik Modelinden üretilen değişkenlerin hangileri olacağına karar vermede toprak oluşumu ve toprak özelliklerinin dağılımı konularını içeren literatürlerden yararlanılmıştır. Çizelge 3.2'de üretilen ve modellemede çevresel (tahmin edici-bağımsız) değişken olarak kullanılan topoğrafik değişkenler ve ilgili literatürler verilmiştir.

Çizelge 3.2. Sayısal yükseklik modelinden üretilen çevresel değişkenler

Değişkenler	Açıklama	Referans
Yükseklik(m)	Aster GDEM'den üretilen arazi yüzeyinin yüksekliğini tanımlar.	Hengl ve Reuter, (2008); Gruber ve Peckham, (2009)
Eğim (%)	Belirli bir mesafedeki yükselti artışının oranını tanımlar.	
Bakı (0° -360°)	Eğim yönü olarak tanımlanır.	
Eğrilik	Eğimin şeklini tanımlamaktadır.	
Profil Eğrilik	Akışın hızlanmasını ve yavaşlamasını ve dolayısıyla erozyonu ve birikmeyi etkiler.	
Planform Eğrilik	Akışın yakınsaklığını ve ayrışmasını etkiler.	
Akış Doğrultusu	Akış yönlerinin atanması, akışı yönlendirmek için hücreler arasındaki yükseklik farkına dayanır.	
Akış birikimi	Bir toplama alanının mekânsal kapsamını tanımlar.	
Topografik Islaklık indeksi	Topografya ve eğimlerdeki su hareketini ilişkilendirir; topografyanın, alanların yeri ve büyüklüğü üzerindeki etkilerini açıklar.	
Akış Gücü İndeksi	Potansiyel akış erozyonunu ve ilgili arazi süreçlerini açıklar.	
Eğim Uzunluğu	Potansiyel olarak erozyona hassas bölgeleri belirlemek için kullanılır.	

Kullanılan değişkenlerden Akış Doğrultusu ve Akış birikimi ArcGIS yazılımında, Arctoolbox-Spatial Analyst- Hydrology- Flow Direction ve Flow Accumulation araçları ile hesaplanmıştır.

Yükseklik, Eğim, Bakı, Eğrilik, Profil eğriliği, Planform eğriliği, Arctoolbox-Spatial Analyst-Surface aracında mevcut bulunan modüller aracılığı ile hesaplanmıştır.

Topoğrafik Islaklık İndeksi (TWI);

$$TWI = \ln\left(\frac{As}{\tan\beta}\right) \quad (3.1)$$

As , Spesifik toplama alanıdır (birim çevre uzunluğu başına katkıda bulunan alan)

$\tan\beta$, radyan cinsinden Spesifik toplama alanı eğimidir.

As , su alma eğiliminin bir parametresidir, $\tan\beta$, yerel eğimi ve kontur uzunluğu ile suyu aktarma eğilimini tanımlar. Sızma ve yüzey akışa geçiş için mekânsal durum koşulları değişmez koşullar kabul edilir. İndeks, doğal logaritma ile ölçeklenir. Su birikimine yatkın alanlar ve düşük eğim açısı ile karakterize edilen alanlar, yüksek topoğrafik ıslaklık indeksi değerlerine sahip olacaktır. Öte yandan, iyi drene edilmiş kuru alanlar (dik eğimler) düşük topoğrafik ıslaklık indeksi değerleriyle ilişkilendirilir (Agren vd., 2014; Mattivi vd., 2019).

Akış Gücü İndeksi (SPI);

$$SPI = \ln(As * \tan\beta) \quad (3.2)$$

As, Spesifik toplama alanıdır (birim çevre uzunluğu başına katkıda bulunan alan)

$\tan\beta$, radyan cinsinden Spesifik toplama alanı eğimidir.

Su akışının potansiyel aşındırıcı gücünü araştırmak için yararlıdır Artan As ve $\tan\beta$, su akış hızının ve su miktarının artmasına ve sonuç olarak suyun aşındırma gücünün artmasına neden olur (Tağıl ve Jenness, 2008; Li vd., 2020; Osat vd., 2016).

Eğim Uzunluğu Faktörü (LS);

$$\left(\frac{As}{22.13}\right)^{0.4} * \left(\frac{\sin \beta}{0.0896}\right)^{1.4} \quad (3.3)$$

As, Spesifik toplama alanı,

LS faktörü, toprak erozyonu üzerindeki topografik etkileri gösteren eğim uzunluğu (L) ve eğim dikliğinin (S) birleşen etkisini gösterir. Eğimin uzunluğu arttıkça, kümülatif akış miktarı ve oranı artar. Evrensel toprak kaybı denkleminin uzunluk-eğim faktörü (LS) potansiyel olarak hassas bölgeleri belirlemek için uygundur (Moore vd., 1993).

3.1.2.2. Uydu görüntüsünden üretilen çevresel değişkenler

3.1.2.2.1. Landsat 7 ETM+ uydu görüntüsü

Çalışma alanına ait uydu görüntüsü “<https://earthexplorer.usgs.gov>” adresinden indirilmiştir (USGS, 2019). Etütün yapıldığı yer ile ilgili 178-34 yol-satır(path-row) çerçevesinde, toprakların çoğunlukla çıplak olduğu, toprak işleme dönemine karşılık gelen tarihlerden olan 15/11/2002 tarihli Landsat 7 ETM+ uydu görüntüsü temin edilmiştir. Bitkisiz dönem görüntüsü, bitki örtüsünün düşük olduğu dönemde toprak yüzeyinden yansıyan enerjiyi en üst düzeye çıkarmak için Landsat arşivinden seçilmiştir (Browning ve Duniway, 2011). Araziye ait geometrik düzeltmeler yapılmıştır (Lillesand vd., 2000).

ArcGIS 10.2’de bantlarına ayrılmış ve atmosfer üstü yansıma değerleri Landsat 7 Science Data Users Handbook, (2019)’da belirtilen metotlar doğrultusunda gerçekleştirilmiştir. Uydu görüntülerine ait çevresel değişkenler ilgili ön işlemler sonrası üretilmiştir. Çalışılan uydu görüntüsünün mekânsal ve spektral çözünürlük bilgileri Çizelge 3.3’de verilmiştir (Landsat 7 Science Data Users Handbook, 2019). Zamansal çözünürlüğü 16 gün, Radyometrik çözünürlüğü ise 8 bittir (Wulder vd., 2019).

Çizelge 3.3. Landsat 7 ETM+ uydusu mekânsal ve spektral çözünürlük bilgileri

Bant	Nitelik	Spektral Aralık (µm)	Mekansal Çözünürlük (m)
1	Mavi	0.450 – 0.520	30
2	Yeşil	0.530 – 0.610	30
3	Kırmızı	0.630 – 0.690	30
4	Yakın Kızılötesi	0.780 – 0.900	30
5	Kısa Dalga Kızılötesi 1	1.550 – 1.750	30
6	Termal	10.40 – 12.50	60
7	Kısa Dalga Kızılötesi 2	2.090 – 2.350	30
Pankromatik	Görünür+Yakın Kızılötesi	0.520 – 0.900	15

Çalışmada kullanılan uydu görüntüsü kayıt numarası LE07_L1TP_178034_20021115’dir. Ürün “Collection 1” olarak adlandırılmaktadır. Zaman serisi analizi için uygun olduğu düşünülen en yüksek kaliteli seviye-1 hassas arazi (L1TP) verilerini içerir. Coğrafi kayıt tutarlıdır ve öngörülen toleranslar dahilindedir (ortalama kök kare hatası (RMSE) <12m) (Anonim, 2021). Seviye-1 ürünü ile birlikte verilen meta veri dosyasında sağlanan radyometrik yeniden ölçekleme katsayıları kullanılarak atmosfer üstü (TOA) yansımasına veya parlaklığına yeniden ölçeklendirilebilir. Meta veri dosyası ayrıca termal bant verilerini TOA parlaklık sıcaklığına dönüştürmek için gereken termal sabitleri içerir. Bu dönüşümler için bilgiler uydu görüntüsü ile birlikte meta veri dosyasında bulunur.

Landsat seviye-1 verileri, MTL (meta veri) dosyasındaki ışıınım yeniden ölçeklendirme faktörleri kullanılarak atmosfer üstü (TOA) spektral ışımasına dönüştürülebilir.

Atmosfer Üstü Işınlıma Dönüştürme;

$$L\lambda = ML * Qcal + AL \quad (3.4)$$

$L\lambda$, Atmosfer Üstü Işınlım,

ML , Meta verilerden banda özgü çarpımsal ölçeklendirme faktörü ($RADIANCE_MULT_BAND_x$; burada x , bant numarasıdır),

AL , Meta verilerden banda özgü ek ölçek değıştirme faktörü ($RADIANCE_ADD_BAND_x$; burada x , bant numarasıdır)

$Qcal$, Nicelleştirilmiş ve kalibre edilmiş standart ürün piksel değeri (DN), ilgili bant atmosfer üstü ışınlıma dönüştürme işlemi, her bir bant için, raster hesaplama araçları ile yapılabilir.

Landsat seviye-1 verileri, MTL (metaveri) dosyasındaki yeniden ölçeklendirme katsayıları kullanılarak Atmosfer Üstü (TOA) Yansımasına dönüştürülebilir.

Atmosfer Üstü (TOA) Yansımasına Dönüştürme;

$$P\lambda' = MP * Qcal + Ap \quad (3.5)$$

$P\lambda'$, Güneş açısı düzeltmesi olmaksızın atmosfer üstü (TOA) yansıması

MP , Meta verilerden banda özgü çarpma ölçeklendirme faktörü ($REFLECTANCE_MULT_BAND_x$; burada x , bant numarasıdır)

$Qcal$, Nicelleştirilmiş ve kalibre edilmiş standart ürün piksel değeri (DN), ilgili bant

Ap , Meta verilerden banda özgü ek ölçek değıştirme faktörü ($REFLECTANCE_ADD_BAND_x$; burada x , bant numarasıdır)

Güneş ışığı geliş açısı dikkate alınarak bir düzeltme ile atmosfer üstü (TOA) yansıması elde etmek için,

$$P\lambda = \frac{P\lambda'}{\cos(\theta SZ)} = \frac{P\lambda'}{\sin(\theta SE)} \quad (3.6)$$

$P\lambda$, Güneş ışığı geliş açısı düzeltilmesi yapılmış atmosfer üstü (TOA) yansımaya değeri, θ_{SE} , Yerel güneş yükseklik açısı. Çerçeve merkezi derece yükselme açısı meta verilerden (SUN_ELEVATION) sağlanır.

θ_{SZ} , Güneş ışınları ile dikey arasındaki açı,

$$\theta_{SZ} = 90^\circ - \theta_{SE} \quad (3.7)$$

Formülü ile elde edilebilmektedir.

İşlemler, çevresel değişken olarak kullanılacak indekslerin elde edileceği Landsat 7 ETM+ bantlarında yapılmıştır.

3.1.2.2.2. Sentinel 2A MSI uydu görüntüsü

Çalışma alanına ait Sentinel 2A-MSI uydu görüntüsü, toprak örneklemelerine en yakın tarih olan 16/11/2019 tarihli T36STH çerçevesinde, Copernicus Open Access Hub "<https://scihub.copernicus.eu>" adresinden indirilmiştir. Kayıt numarası S2A_MSIL2A_20191116T085231_N0213_R107_T36STH olan Sentinel uydu görüntüsü L2 seviyesidir. Bu seviyedeki bir uydu görüntüsü, Bottom-Of-Atmosphere, (Atmosfer altı yansımaya) düzeltmeleri yapılmış yansımaya ürünüdür (ESA, 2015). Çalışılan uydu görüntüsünün mekânsal ve spektral çözünürlük bilgileri Çizelge 3.5’de verilmiştir. Her bir Sentinel-2 uydusunun zamansal çözünürlüğü 10 gündür ve entegre 2 uydu için zamansal çözünürlüğü 5 gündür. Sentinel 2 uydusunun A ve B serileri yeryüzünde aynı alana ait 5 gün zamansal çözünürlükte görüntü alabilmektedir. Radyometrik çözünürlüğü 12 bittir. (ESA, 2015).

Her 2 uydu görüntülerinde de bantlar arası matematiksel işlemler sonucu elde edilen, toprağı ve bitki örtüsü faktörlerini temsil edecek değişkenler Çizelge 3.4’de verilmiştir.

Çizelge 3.4. Uydu görüntülerinden üretilen çevresel değişkenler

İndeks	Denklem
Normalize Bitki Fark İndeksi (Tucker, 1979).	$\frac{Yakın\ Kızılötesi - Kırmızı}{Yakın\ Kızılötesi + Kırmızı}$
Normalize Toprak Ayarlı Bitki İndeksi (Huete, 1988)	$\frac{Yakın\ Kızılötesi - Kırmızı}{Yakın\ Kızılötesi - Kırmızı} * (1 + L)$ L: Çoğu arazi örtü tipi için 0.5 alınır.
Normalize Karbonat İndeksi (Brown vd., 2017)	$\frac{Kırmızı - Yeşil}{Kırmızı + Yeşil}$
Normalize Demir İndeksi (Brown vd., 2017)	$\frac{Kırmızı - K. dalga\ kızılötesi}{Kırmızı + K. dalga\ kızılötesi}$
Normalize Kil İndeksi (Brown vd., 2017)	$\frac{KDKÖ(a) - KDKÖ(b)}{KDKÖ(a) + KDKÖ(b)}$
Normalize Çıplak Toprak İndeksi (Brown vd., 2017)	$\frac{K. Dalga\ Kızılötesi2 - Yeşil}{K. Dalga\ Kızılötesi2 + Yeşil}$
Normalize FeO ⁺² İndeksi (Brown vd., 2017)	$\frac{KDKÖ(a) - YKÖ}{KDKÖ(a) + YKÖ}$
Üst Toprak Tane Büyüklük İndeksi (Xiao vd., 2006)	$\frac{(Kırmızı - Yeşil)}{(Kırmızı + Yeşil + Mavi)}$
Normalize Kireçli Sediment İndeksi (Boettinger vd., 2008)	$\frac{K. Dalga\ Kızılötesi1 - Yeşil}{K. Dalga\ Kızılötesi1 + Yeşil}$
Parlaklık İndeksi (Hounkpatin vd., 2018)	$\sqrt{(Mavi^2 + Yeşil^2 + Kırmızı^2)} / 3$
Hue İndeksi (Hounkpatin vd., 2018)	$\frac{(2 * Kırmızı - Yeşil - Mavi)}{Yeşil - Mavi}$
Saturasyon İndeksi (Hounkpatin vd., 2018)	$\frac{Kırmızı - Mavi}{Kırmızı + Mavi}$

Çizelge 3.5. Sentinel 2A-MSI uydusu mekânsal ve spektral çözünürlük bilgileri

Bant	Nitelik	Dalgaboyu (nm)	Mekansal Çözünürlük (m)
1	Kıyı aerosol	443	60
2	Mavi	490	10
3	Yeşil	560	10
4	Kırmızı	665	10
5	Vejetasyon Kırmızı Kenar	705	20
6	Vejetasyon Kırmızı Kenar	740	20
7	Vejetasyon Kırmızı Kenar	783	20
8	Yakın Kızılötesi	842	10
8a	Vejetasyon Kırmızı Kenar	865	20
9	Su Buharı	945	60
10	Kısa dalga Kızılötesi-Saçakbulut	1380	60
11	Kısa dalga Kızılötesi1	1610	20
12	Kısa dalga Kızılötesi2	2190	20

3.1.3. Mevcut toprak haritasından veri alınması

Toprak sınıflarını haritalamak için eski toprak profil verilerinden ve toprak etüt haritası haritalama birimlerinden elde edilen eğitim verilerinin kullanımının karşılaştırılması amacıyla yapılan çalışmalarda, alan ağırlıklı örnekleme metodolojisinin en yüksek sınıf doğrulukları sağladığı bildirilmiştir (Moran ve Elisabeth, 2002; Heung vd., 2017; Collard vd., 2019). Bununla birlikte, tahminde kullanılacak değişkenlerin ve gözlemlerin benzersiz kombinasyonu için (Harrell, 2001) en az 5 ve mümkünse belirli bir toprak taksonomik varlığın 10 gözleminin bulunması gerekliliği bildirilmektedir. Benzer yaklaşımla; toprak sınıflarını haritalamak için eski toprak profil verilerinden ve toprak etüdü haritalama birimlerinden elde edilen eğitim verilerinin kullanımının karşılaştırılması amacıyla 1 km² için 2 ile 10 arasında örnekle temsil edilebildiğine ait bilgiler bulunmaktadır (Marchetti vd., 2011; Collard vd., 2014).

Bu yaklaşımla, bu tez çalışmasında, taksonomik sınıflandırma seviyelerinden en düşük seviye olan seri bazında örnek noktaları oluşturulmuştur. 1 km²'den küçük seri mevcut olduğu için, en az 5 örnekle temsil etmek amacıyla alan ağırlıklı hesap edilmiş ve toplamda CBS ortamında 503 nokta belirlenmiştir.

Arazi gözlemlerinde 91 örnek seri ölçeğinde kontrol edilmiştir. Bu 91 örnek, güncel Sentinel 2A MSI uydu görüntüsünden elde edilen değişkenler ve topoğrafik değişkenler ile toprak özellikleri arasındaki ilişkilerin belirlenebilmesi amacıyla, laboratuvara getirilmiş ve Çizelge 3.6'da bildirilen analizler yürütülmüştür.

Çizelge 3.6. Toprak örneklerinde yapılan analizler

Analiz	Yöntem
Tane boyut dağılımı (Tekstür)	(Bouyoucos, 1962)
pH	(Kacar, 2016)
EC (mS)	(Kacar, 2016)
Katyon Değişim Kapasitesi (KDK)	(Kacar, 2016)
% CaCO ₃ Eşdeğeri	(Allison ve Moodie, 1965)
% Organik madde	(Walkley ve Black, 1934)
Değişebilir (Sodyum) Na	(Kacar, 2016)
% Na oranı	$\% Na = \frac{Na}{KDK} * 100$ Na ve KDK=cmol kg ⁻¹ (Işık ve Usta, 2004)

3.2. Yöntem

3.2.1. Toprak sınıflarının denetimli sınıflandırma ile sayısal haritalanması

3.2.1.1. Çok terimli lojistik regresyon

Bağımlı değişkeninin kategorik olduğu durumlarda, tahmin için doğrusal regresyonun basit bir uzantısı olan Lojistik Regresyon (LR) kullanılabilir. Bağımlı değişken için yalnızca iki olası sonucun olduğu durumlarda lojistik regresyona ikili(binary) lojistik regresyon denir (Alpaydın, 2010). Bağımlı değişken ikiden fazla olası kategori aldığı anda (örneğin, Çizelge 3.1’de sunulan Toprak Taksonomisi ve FAO Dünya referans sistemi kategori düzeyleri), tahmin için Çok Terimli Lojistik Regresyon (MNLR) olarak bilinen bir ikili lojistik regresyon genellemesi kullanılır. Çok terimli lojistik regresyon, çok sınıflı bir bağımlı değişkenin olası sonuçlarının olasılıklarını, belirli bir açıklayıcı değişkenler kümesinin (örneğin, Çizelge 3.2’de sunulan topoğrafik çevresel değişkenler ve Çizelge 3.4’de sunulan uzaktan algılama ürünü indeksler) doğrusal bir kombinasyonu olarak modellemek için maksimum olasılığı kullanır (Hosmer vd., 2013; Afshar vd., 2018).

Denetimli öğrenme algoritmalarının çoğu, $P(y | x)$ olasılık dağılımını tahmin etmeye dayanır. Bunu basitçe, parametrik dağılım ailesi $P(y | x; \theta)$ için en iyi parametre vektörünü (θ) bulmak için maksimum olasılık tahminini kullanarak yapabilmektedir. Amacımızın verilen x değişkenleri ile y ’yi tahmin etmek için koşullu bir olasılık $P(y | x; \theta)$ tahmin etmek olduğu durumuna genellenebilmektedir.

$P / (1 - P)$ oranına, X çevresel değişkenleri verildiğinde $Y=1$ olayının olasılığı denilir. Nitekim olasılıklar 0 ile 1 arasında değişirken, oranlar 0 ile $+\infty$ arasında değişmektedir. Olasılıkların logaritması ise $-\infty$ ile $+\infty$ arasında değişir. Doğrusal bir model sonucu $a + b_j x_j$ olarak ifade edilir ve sınırsız değer alabilir. Bu nedenle, doğrusal olarak oluşturulan bir modelin sonuçlarının olasılıksal değerlendirilmesi ile sınıflandırma süreci yürütülmektedir.

Sayısal toprak haritalamaya uyarlanması aşamasında,

Logit (ℓ), bir pikselin (i), bir toprak sınıfın (j) üyesi olma olasılığı (P) ve olmama olasılığı (1 -P) arasındaki oranın logaritmik fonksiyonu olarak tanımlanabilir.

İkili bir sınıf çıktısında sigmoid fonksiyonu doğrusal model çıktılarına olasılıksal olarak 0 ile 1 arasında hesaplamaktadır.

$$Sigmoid(P_{ij}) = \frac{e^x}{1+e^x} = \frac{1}{1+e^{-x}} = 1 + e^x = \frac{1}{P_{ij}} = e^{-x} = \frac{1-P_{ij}}{P_{ij}} = e^x = \frac{P_{ij}}{1-P_{ij}} \quad (3.8)$$

Her iki tarafın logaritması alındığında;

$$x = \log\left(\frac{P_{ij}}{1-P_{ij}}\right) \quad (3.9)$$

x, Doğrusal bir model sonucu olduğunda,

$$lij = \log\left(\frac{P_{ij}}{1-P_{ij}}\right) = \beta_{0j} + a_{1j}.X_{1i} + a_{2j}.X_{2i} + \dots + a_{nj}.X_{ni} \quad (3.10)$$

β_{0j} , j toprak sınıfı için bir regresyon eğrisi kesişim değerini(intercept) gösterir.

a_{1j} , j toprak sınıfını temsil eden X çevresel değişkeninin katsayısıdır (coefficient).

n, toprak sınıfı j ile önemli ölçüde ilişkili olan ortak değişkenlerin toplam sayısıdır.

Bu model, bağımlı değişkenin olasılık dağılımının binom(ikili), yerine çok terimli olması dışında lojistik regresyon modeline benzer. i pikselinin bir toprak sınıfı j'ye ait olma olasılığının tahmini şu şekilde elde edilebilir (P_{ij}):

$$P_{ij} = \frac{e^{lij}}{1 + \sum_{j=1}^{k-1} e^{lij}} \quad (3.11)$$

Burada k, bağımlı kategorilerin toplam sayısıdır ve $\sum$, pikseli için tüm toprak sınıflarının (referans grubu hariç) logitlerinin toplamını gösterir Kategorik hedef değişkenler (toprak sınıfları) seviyeleri ikiden fazla kategori içerir. Modelde bağımlı kategorik değişken sayısının 1 eksiği kadar model oluşturulur. Bu nedenle, bu modelde referans kategorisi seçilmelidir.

Referans kategorisi (r) olasılığı şu şekilde hesaplanır:

$$Pr = \frac{1}{1 + \sum_{j=1}^{k-1} e^{lij}} \quad (3.12)$$

Çok Terimli Lojistik Regresyonu (MNLR), kullanarak yapılan modelleme sürecinde R Core Environment (R Core Team, 2020) yazılımında “nnet” paketi kullanılmıştır (Venables ve Ripley, 2002). Veri seti, %70 eğitim verisi, %30 test verisi olarak bölünmüştür. Bağımlı değişkenler (toprak sınıfları) 2'den fazla seviyeye sahip olduğundan, "nnet" paketinde "softmax fonksiyonu" çalıştırılır. Çok terimli lojistik regresyon algoritması sonucu bir pikselin farklı toprak sınıflarına ait olma olasılığı bulunur (Malone vd., 2017). Olasılık değeri 0 ile 1 arasındadır ve olasılık değerleri toplamı 1'dir. Piksel, en yüksek olasılığı bulunan toprak sınıfına atanır. Mekânsal olarak toprak sınıflarının tahmini R Core Environment programının Tümüleşik Geliştirme Ortamı (IDE) olan R Studio V 1.3'te gerçekleştirilmiştir (RStudio Team, 2020).

Veri setinde yer alan tüm ordo, alt ordo, büyük grup, alt grup, seri ve Dünya referans sistemi 2. seviye toprak grupları olası kategorilerdir. Bağımlı değişken olan toprak sınıflandırma sistemlerinin tüm kategorilerinde ikiden fazla seviyesi mevcuttur. Modeli çalıştırmadan önce referans sınıf seçilmelidir; bu durumda her seviye düzeyinde kurulan modellerde bu seçilmiştir (ilk önce varsayılan alfabetik sırada). Her bir bağımlı değişken için her bir tahmin edici çevresel değişkenin regresyon katsayısının önemi, belirli bir tahmin edici değişkenlerdeki değişikliklerin, bağımlı değişkenin olasılık oranında önemli bir değişikliğe yol açıp açmadığını test eder (Hosmer ve Hjort, 2002; Gevrey vd., 2003). Böylece, her bir öngörücünün önemini çıkartılmakta, mutlak değer ne kadar büyükse, önemi o kadar büyük olmaktadır. Önem seviyeleri 0-100 arasında gösterim yapılmıştır (Stum vd., 2010; Pahlavan-Rad vd., 2020; Sahragard ve Pahlavan-Rad, 2020). Önem seviyeleri pedolojik yorumlamada kolaylık sağlayabilecektir.

3.2.1.2. Doğruluk değerlendirmesi

Toprak sınıflarının tahmin doğruluğu, genel doğruluk, üretici doğruluğu ve kullanıcı doğruluğu kullanılarak ölçülür. Bu ölçütler, her bir sınıf için doğru ve yanlış tahmin edilen gözlemlerin sayısını karşılaştıran bir karışım matrisinin gözden geçirilmesi ile en iyi şekilde anlaşılmaktadır. Genel doğruluk, tüm veri kümesinde doğru sınıflandırılmış gözlemlerin oranıdır. Kullanıcı doğruluğu (“dâhil etme hatası” veya hassasiyet olarak da bilinir), gözlemlenen sınıfa, uygun tahmin edilen bir sınıfın oranıdır. Üretici doğruluğu (“ihmal hatası” veya özgüllüğü), tahmin edilen sınıfa uygun gözlemlenen bir sınıfın oranıdır (Congalton, 1991; Kuhn ve Johnson, 2013). Bu matris, sınıf olasılığına göre en yüksek olasılıklı sınıfa atanmış ve o sınıf etiketi almış şekilde haritada bulunan her pikselin orijinal toprak haritasına karşılık gelen sınıflarıyla karşılaştırır. Her sınıf için kullanıcı doğruluğu, her bir sınıf için doğru tahmin edilen gözlem sayısının, satır toplamına bölünmesiyle hesaplanmıştır. Her sınıf için üretici doğruluğu, her bir sınıf için doğru tahmin edilen gözlem sayısının, sütun toplamına bölünmesiyle hesaplanmıştır.

$$\text{Genel doğruluk} = \sum_{i=1}^n X_{ii}/N \quad (3.13)$$

n , matristeki satırların (kare matris dolayısıyla sütunların) sayısıdır, X_{ii} , satır ve sütunun karşılaştığı köşegen bir hücredeki sayıdır (herhangi bir sınıfın doğru sınıflandırma sayısı).

$$\text{Kullanıcı doğruluğu} = \frac{tt}{tt+tf} \quad (3.14)$$

$$\text{Üretici Doğruluğu} = \frac{tt}{tt+ft} \quad (3.15)$$

tt : doğru tahmin edilen sınıf sayısı, tf : tahmin edilen ama gözlemlenmeyen, ft : gözlemlenen ancak yanlış tahmin edilen sınıf sayılarıdır.


$$Kappa\ katsayısı = \frac{Po-Pe}{1-Pe}$$

Po: Genel doğruluk, Pe: Beklenen doğruluk,

$$Pe = \sum_{i=1}^n \left(\frac{X_{io}}{N} \right) + \left(\frac{X_{oi}}{N} \right) \quad (3.16)$$

N: toplam gözlem sayısı, n, sınıf sayısı, Xio, her bir toprak sınıfındaki toplam gözlem sayısını, Xoi, Doğru tahmin edilen toprak sınıf sayısıdır. Karışım matrisi ile sınıflandırmaların performansını ölçmek için “ithir” paketi kullanılarak yürütülmüştür (Malone, 2018). Değerlendirmeler eğitim ve test setlerinde yürütülmüştür. İlgili metodolojiye dair gösterim Şekil 3.4’de verilmiştir.





Şekil 3.4. Çok terimli lojistik regresyon metodu ile toprak sınıflarının sayısal haritalanması iş akışı

3.2.2. Toprak sınıflarının denetimsiz sınıflandırma ile sayısal haritalanması

Toprak haritalarında eğitim verisi olarak toprak profillerinin bulunmadığı durumlarda veya yalnızca haritalama ünitelerinin bulunduğu durumda haritalama ünitesinin dağılımını belirleyebilmek amacıyla K-ortalamları kümeleme yaklaşımları gibi denetimsiz sınıflandırma yöntemleri uygulanabilmektedir. K-ortalamları kümeleme yaklaşımı, çevresel değişkenlerden kümeler oluşturmak için kullanılmış ve ardından her kümeye harita açıklamasının toprak sınıfları atanmıştır. Ordo (4 sınıf), Alt ordo (4 sınıf), Büyük grup (5 sınıf), Alt grup (10 sınıf), Seri (20 sınıf) ve FAO Dünya referans sistemi 2.seviye toprak grupları (8 sınıf) toprak sınıfının bulunduğu çalışma alanında, denetimsiz sınıflandırma k-ortalama kümeleme yaklaşımı ile elde edilen kümeler, uzman bilgisinin kontrolünde, arazideki toprak tipi dağılımına göre harita açıklamasındaki her toprak sınıfına atanmıştır. Sınırların içerisindeki değişim ve farklılıklar her bir sınıflandırma seviyesi ölçeğinde yorumlanmıştır.

K-ortalama yönteminde, N boyutundaki ($M \times N$ matrisi) M noktasını K kümelerine bölerek küme içi karelerin toplamı en aza indirgenmektedir.

Algoritma, girdi olarak N boyutunda M noktalarının matrisini (534 satır, 474 sütun boyutunda, 23 çevresel değişken veri seti yığını) ve N boyutunda K ilk küme merkezlerinin bir matrisini gerektirir. K-ortalama kümeleme aşağıdaki adımlardan oluşur (Hartigan ve Wong, 1979),

-Veri noktaları X_i ve küme sayısı (K) belirlenir. Bir sonraki adım aşağıdaki gibi devam edebilecektir;

$i=1,2,\dots,n$

Veri noktaları rastgele olarak kümelere tahsis edilir, ardından her bir C_j küme merkezi hesaplanır.

$j=1,2,\dots,k$


Kümelerin merkezleri belirlenir (C_j)

Her küme içinde her bir piksel, kendi küme merkezine Öklid uzaklığı, hataların karesi toplamı olarak hesaplanır. Burada "hata", her örneğin, her kümenin en yakın merkezine olan mesafesini gösterir. Daha sonra hata karelerin toplamı (ESS), aşağıdaki formülle tüm kümelerin toplamı olarak hesaplanır.

$$Hata\ Karelerinin\ toplamı\ (HKT) = \sum_{j=1}^k \sum_{i=1}^n |X_{ij} - C_j|^2 \quad (3.17)$$

C_j ; j sınıfının küme merkezi, X_{ij} ; j kümesindeki pikseldir.

Veri noktalarını en yakın kümeye yeniden atanır ve her ayırmadan sonra her kümenin merkezi güncellenir. Nokta verilerinin kümelere yeniden atanması durana kadar 3. ve 4. adımlar tekrarlanır. Minimum hata karelerin toplamına dair eşik değeri elde edildiğinde veya yineleme sayısı bittiğinde algoritma durur. 23 çevresel değişkenin R Core Environment programında tek bir katman olarak istiflenmesi için “utils” paketindeki “stack” fonksiyonu kullanılmıştır (R Core Team, 2020). K-ortalama kümeleme algoritmasını çalıştırmak için "RStoolbox" paketi içerisindeki "unsuperClass" fonksiyonu kullanılmıştır (Leutner vd., 2019). İlgili metodojinin iş akış diyagramı Şekil 3.5’de verilmiştir




Şekil 3.5. K ortalamaları algoritması ile toprak sınıflarının sayısal haritalanması iş akışı

3.2.3. Toprak sınıflarının bilgiye dayalı yaklaşım ile sayısal haritalanması

Denetimsiz öğrenme ve çok terimli lojistik regresyon sonucu model tahmininde önem arz eden çevresel değişkenler göz önünde bulundurularak, ArcGIS “Raster Calculator” aracı ile koşul ifadeleri yazılarak mümkün olabilecek toprak sınıflandırma seviyelerinin tespiti yapılmıştır.

İlgili metodolojinin iş akış diyagramı Şekil 3.6’da verilmiştir.



Şekil 3.6. Bilgi temelli yaklaşım ile toprak sınıflarının sayısal haritalanması iş akışı

3.2.4. Toprak özellikleri ile çevresel değişkenler arasındaki ilişkilerin belirlenmesi

Mevcut toprak haritalarından elde edilen verilerin sınıflandırma çalışmalarında kullanımına yönelik toprak sınırlarının içerisinde alınan örnekler kullanılmıştır. Arazide kontrol amaçlı yapılan çalışmalarda 91 koordinatlı noktadan toprak örnekleri alınmış ve bu koordinat noktalarındaki Çizelge 3.2’de ki topoğrafik verilerden üretilen çevresel değişkenlere ek olarak, toprak örneklerinin alındığı tarihe yakın bir tarihte alınmış Sentinel 2A-MSI uydu görüntüsünden üretilmiş Çizelge 3.4’de ki görüntü indeksleri kullanılarak veri matrisi oluşturulmuştur.

Alınan toprak örneklerinde Çizelge 3.6’da bildirilen analizler yürütülmüş ve sonuçları veri matrisine işlenmiştir.

Veri matrisi oluşturma sürecinde, 11 adet topoğrafik çevresel değişken ve 12 adet Sentinel 2A MSI uydu görüntüsünden üretilmiş indis verileri, R Core Environment programında tek bir katman olarak istiflenmesi için “utils” paketindeki “stack” fonksiyonu kullanılmıştır (R Core Team, 2020).

Koordinatlı 91 noktanın bulunduğu konumlardaki çevresel değişken değerleri “raster” paketi içerisinde bulunan “extract” fonksiyonu kullanılarak, elde edilmiştir (Hijmans, 2020).

Oluşturulan veri setinde öncelikli olarak R Core Environment programında, (R Core Team, 2020), “psych” paketi içerisinde “describe” fonksiyonu kullanılarak tanımlayıcı istatistikleri yapılmıştır (Revelle, 2020).

Toprak özellikleri ile çevresel değişkenler arasındaki karşılıklı ilişki derecesini belirlemek için korelasyon katsayısı kullanılmıştır. Veri matrisinde R Core Environment (R Core Team, 2020) programında “stats” paketinde korelasyon işlemleri gerçekleştirilmiş, “corrplot” (Wei ve Sinyo, 2020) paketi kullanılarak korelasyon grafikleri oluşturulmuş, $P < 0.05$ düzeyinde önemli olanlar belirlenmiştir.

Toprak özelliklerinin çevresel değişkenler ile tahminine yönelik Çoklu doğrusal regresyon metodu kullanılmıştır.

Doğrusal regresyon modelleri, bağımlı bir değişkeni, tahmin edicilerin doğrusal bir kombinasyonu (bağımsız değişkenler-çevresel değişkenler) ile açıklamayı amaçlamaktadır (Forkuor vd., 2017). Bu çalışmada, spektral ve topoğrafik değişkenler bağımsız değişkenler iken, çeşitli toprak parametreleri bağımlı değişkenler olarak kabul edilmiştir.

$$y = \alpha + \sum_{i=1}^n b_i * x_i \pm \varepsilon \quad (3.18)$$

y, bağımlı değişken(toprak özelliği), x_i , bağımsız değişken(spektral ve topoğrafik değişkenler), n, değişken sayısı, α , kesişim katsayısı, b_i , kısmi regresyon katsayısı, ε ise standart hatadır.

Standart tahmin tekniklerine sahip standart doğrusal regresyon modelleri, tahmin edici bağımsız değişkenler, Bağımlı yanıt değişkenleri ve bunların ilişkileri hakkında bir dizi varsayımda bulunur.

Regresyon analizine geçmeden önce, regresyon modeline uygunluğunda değerlendirmek için veri dönüştürülmesinin gerekip gerekmediğini görmek için bağımlı hedef değişkenin histogramı incelenmesi önerilir. Değerlerin frekans dağılımı, ortalaması etrafında simetrik olan çan şeklindeki bir eğriyi izlediğinde, seçilen toprak özelliği için veriler normaldir. Normalliği değerlendirmek için normallik testleri kullanılabilir. Normallik testi verilerin normal dağılmadığını gösteriyorsa, verilerin normallik varsayımını karşılayacak şekilde dönüştürülmesi gerekebilir (FAO, 2018).

Veri setindeki parametrelerin tanımlayıcı istatistiksel analizleriyle birlikte veri setinin normal dağılıma uygunluğu çarpıklık ve basıklık katsayıları ve bu katsayılarla ait standart sapma ile değerlendirilmiştir. Basıklık veya çarpıklık katsayısı, standart sapmanın 2 katından küçük olması durumunda parametrenin normal dağılım gösterdiği varsayılmıştır (Berkman ve Reise, 2012; Durgun vd., 2017). Normal dağılmayan parametreler, logaritmik dönüşüm uygulanarak normal dağılıma yaklaştırılabilmektedir (Webster, 2001).


Modelin tahmin doğruluğunu değerlendirmek için belirleme katsayısı (R^2) ve Kök ortalama kare hatası (RMSE) kullanılmıştır. R programında “caret” paketi içerisinde mevcut “VarImp” fonksiyonu ile her model parametresi için t istatistik değerinin mutlak değeri baz alınarak modelde kullanılan çevresel değişkenlerin önemi belirlenmiştir.

$$\text{Belirleme Katsayısı } (R^2) = \left[\frac{\sum_{i=1}^n (O_i - O_{ave})(P_i - P_{ave})}{\sqrt{\sum_{i=1}^n (O_i - O_{ave})^2 (P_i - P_{ave})^2}} \right]^2 \quad (3.19)$$

$$\text{Kök Ortalama Kare Hatası (RMSE)} = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (3.20)$$

O_i ve P_i sırasıyla gözlenen ve tahmin edilen değerlerdir. O_{ave} ve P_{ave} değerleri sırasıyla gözlenen değerlerin ve tahmin edilen değerlerin ortalamasıdır. n , veri setindeki örnek sayısıdır.

Çevresel Değişkenler ve toprak özellikleri arasındaki korelasyonlar incelendikten sonra, toprak ve çevresel değişkenleri arasındaki mekânsal ilişkileri değerlendirmek ve toprak sisteminin değişkenliğini açıklamak için bir grup faktör elde etmek amacıyla faydalı istatistiksel teknikler olarak kabul edilen (Shukla vd., 2006) temel bileşen analizi yapılmıştır (SPSS 23, 2015). Toprak özelliklerinin dağılımını koşullandırabilecek en önemli değişkenleri belirleyerek, gözlemlenen faktörlerin en iyi şekilde açıklanması amaçlanmıştır (Shukla vd., 2006; Zeraatpisheh vd., 2019). İlgili metodolojinin iş akış diyagramı Şekil 3.7’de verilmiştir.



Şekil 3.7. Toprak özellikleri ile çevresel değişkenler arasındaki ilişkilerin belirlenmesi iş akışı

4. BULGULAR VE TARTIŞMA


4.1. Çok Terimli Lojistik Regresyon (MNLR)

Çalışma alanında yer alan toprakların kategorik sınıflandırma birimleri için (Çizelge 3.1) ayrı ayrı sayısal haritalama süreçleri yürütülmüştür.


Modellemede kullanılan Landsat 7 ETM+ uydu görüntüsüne ait çevresel değişkenler Şekil 4.1’de verilmiştir. Diğer bir çevresel değişken seti olan topoğrafik değişkenler Şekil 4.2’de verilmiştir.

4.1.1. Ordo düzeyinde toprakların sayısal olarak haritalanması

Örnekleme metodolojisine göre, ordo seviyesindeki toprak sınıfı haritalama birimlerinden Entisol ordosu 81, İnceptisol ordosu, 270, Mollisol ordosu 95 ve Vertisol ordosu 57 nokta ile temsil edilmiştir. Model algoritmasına göre çok terimli lojistik regresyon ile model kurulurken Entisol ordosu referans kategori olarak seçilmiş ve referans kategorisi için model oluşturulmamıştır. Sayısal toprak haritalamanın en önemli yeniliklerinden biri verilerin kolay tekrar kullanımı ve sonuçların yeniden üretilebilir olmasıdır (Gentleman ve Lang, 2007). R programında ordo seviyesi için modelde “set.seed (2021)” kodu ile randomizasyonun alınan örneklerle sabitlenmesi ve aynı sonuçların alınmasını sağlar. Ordo düzeyinde toprak sınıflarının tahmini için kullanılan modele ait değişkenlerin katsayıları Çizelge 4.1’de, ordo düzeyinde toprak sınıflarının doğruluk değerlendirmesi için hesaplanmış karışım matrisi Çizelge 4.2’de verilmiştir. Ordo düzeyinde toprakları sınıflandırmak amaçlı üretilen modelde önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.3’de ve önemli değişkenlere ait kutu grafikleri Şekil 4.4’de verilmiştir. Ordo düzeyinde toprakların en muhtemel sınıfa aitliklerini ve her bir ordonun oluşma olasılıklarının mekânsal haritaları Şekil 4.5’de verilmiştir.



Şekil 4.1. Landsat 7 ETM+ uydu görüntüsünden üretilen çevresel değişkenler




Şekil 4.2. Sayısal yükseklik modelinden üretilen çevresel değişkenler

Çizelge 4.1. Ordo düzeyi toprak sınıflarının tahmininde model değişken katsayıları


Ordo	Kesişim Noktası	Akış Birikim	Akış Doğrultusu	Bakı
Inceptisol	-15.7964	-0.003082038	0.007634986	0.001807674
Mollisol	31.74838	-0.001205186	0.01510728	0.004150069
Vertisol	23.11865	-0.007000011	0.014729337	-0.000575701
Ordo	Eğrilik	Eğim Uzunluğu	Planform Eğriligi	Profil Eğriligi
Inceptisol	0.3098032	0.02223749	-0.1517424	-0.4617914
Mollisol	0.2361391	0.09576118	-1.135289	-1.3713149
Vertisol	0.1817695	0.17833258	-0.3097573	-0.491525
Ordo	Akış Gücü İndeksi	Topografik Islaklık İndeksi	Yükseklik	Eğim (%)
Inceptisol	0.1819498	-0.29018498	0.002391173	-0.18653884
Mollisol	-0.2110087	0.01041459	-0.043559361	0.05311009
Vertisol	0.188761	-0.12808238	-0.032680544	-0.16126691
Ordo	Hue indeks	Nor. Çıplak Toprak İnd.	Nor. Kireçli Sediment İnd.	Nor. Karbonat İnd.
Inceptisol	-1.148097	17.175531	-66.17389	5.542684
Mollisol	0.556177	30.450241	-44.48816	27.857755
Vertisol	15.226015	7.293856	-25.99457	6.303044
Ordo	Nor. Demir (FeO+2) İnd.	Nor. Demir İnd.	Nor. Kil İnd.	Parlaklık İndeksi
Inceptisol	23.54809	-10.53538527	34.109635	-59.40786
Mollisol	24.31052	-5.83677196	18.476864	-47.77369
Vertisol	21.4237	-0.03307393	-5.205236	1.89656
Ordo	Nor. Bitki Fark İnd.	Satursayon İndeksi	Nor. Toprak Ayarlı Bitki İnd.	Üst Top.Tane Büy. İnd.
Inceptisol	4.388941	15.4762	6.583469	22.029036
Mollisol	2.173152	-42.75575	3.259795	9.809708
Vertisol	4.86317	-16.46256	7.294658	-5.960032

Çizelge 4.2. Ordo düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi


		GÖZLEM					
		Eğitim Seti					
		Entisol	Inceptisol	Mollisol	Vertisol	Toplam	Kullanıcı
TAHMİN	Entisol	22	6	0	0	28	%79
	Inceptisol	26	162	30	31	249	%66
	Mollisol	3	16	37	5	61	%61
	Vertisol	1	3	3	7	14	%50
	Toplam	52	187	70	43	228	
	Üretici	%43	%87	%53	%17	Genel D.	%65
	Kappa						0.38=%38
	Test Seti						
	Entisol	10	3	2	0	15	%67
	Inceptisol	18	69	14	10	111	%63
	Mollisol	1	9	9	4	23	%40
	Vertisol	0	2	0	0	2	%0
	Toplam	29	83	25	14	88	
	Üretici	%35	%84	%36	%0	Genel D.	%59
Kappa						0.24=%24	



Şekil 4.3. Ordo düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi



Şekil 4.4. Ordo düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri



Şekil 4.5. Ordo seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları

Çok terimli lojistik regresyon algoritması ile ordo seviyesinde toprakların sayısal haritalanması sonuçlarına göre çalışma alanında genel doğruluk seviyesi eğitim setinde %65 test setinde ise %59 olarak belirlenmiştir. Heung vd. (2016), alan ağırlıklı haritalama ünitelerinden örneklem yaklaşımını kullanarak yaptığı çalışmada ordo seviyesi için %58'lik genel doğruluk hesaplamıştır. Taghizadeh-Mehrjardi vd. (2019), İran'da yaptığı çalışmada çok terimli lojistik regresyon algoritması ile sayısal toprak haritalarının ordo seviyesinde sınıflandırma doğruluğunun %64 olduğunu bildirmiştir. Rasaei vd. (2020), Eski toprak haritalarının çevresel değişken olarak kullanıldığı çalışmaları ordo seviyesinde genel doğruluğu %73 olarak belirlemişlerdir. Giasson vd. (2008), Brezilya'da, 1: 30000 ile 1: 50000 arasında değişen ölçeklerde mevcut toprak haritası bulunan 3 bölgede lojistik regresyonu kullanarak yaptıkları çalışmada, ordo düzeyinde genel doğruluk değerlerinin %61 ile %71 arasında değiştiğini bildirmektedirler. Yüzey örtüsünün ve iklimin daha homojen olduğu alanlarda ordo sınıflandırma doğrulukları yüksek olabilmektedir. Nitekim Mosleh vd. (2017), İran'da kurak bir bölgede yaptıkları çalışmada çok terimli lojistik regresyon algoritmasını kullanarak %95 genel doğruluk ile ordo sınıflarını tahmin edebilmişlerdir. Sınıflandırma doğruluğunu da toprak etüt ve haritalama bilimi kapsamında değerlendirmek gerekirse, Geleneksel toprak haritalamada, bir harita birimindeki birbirine benzemeyen küçük bileşenlerin toplam miktarı genellikle %15 ile %25 arasındadır (Soil Survey Division Staff, 2017). Bu nedenle, bu aralığın, yani toplam çalışma alanını bir harita birimi olarak düşünüldüğünde, her taksonomik seviyede %75 ile %85 arasındaki bir genel doğruluğun eşik değeri olarak kullanılabilecektir (Esfandiarpour-Boroujeni vd., 2020a). Eğitim ve test setlerinde genel doğruluk düzeyinde kabul edilebilir sonuçlara çok yakın doğruluklar elde edilebilmiştir (Çizelge 4.2.). Kullanıcı doğruluğu, üretilen harita üzerindeki sınıf mevcudiyetinin yerdeki mevcudiyetini göstermesi bakımından kullanılabilir. Yüksek kullanıcı doğruluğu, ilgili sınıfın yer gerçeği olarak kullanılan detaylı toprak haritası ile daha iyi uyumu olarak yorumlanabilir (Aitkenhead ve Coull 2019). Sınıf düzeyinde yapılan değerlendirmeye göre; çalışma alanında yüksek oranda bulunan İnceptisol ordosu ortalama %65 kullanıcı doğruluğu değeriyle tahmin edilebilmiştir. Geleneksel toprak haritalamadaki sınırların aksine burada 30 metrelik ölçekte İnceptisolün yüksek doğrulukla sınıflandırılması kayda değerdir. Mollisol ve Entisol için doğruluk değerleri test setinde daha düşük olmakla birlikte %50-70 düzeyinde bir başarı sağlanabilmiştir. Çalışma alanında saha etüdü ile belirlenebilen ancak sayısal toprak

haritalama yaklaşımı ile tahmininde zayıflık bulunan ordo Vertisol olmuştur. Vertisollerin sahada tanımlanmasında gözetilen ana husus, yıl boyunca bir süre derin, geniş çatlaklara sahip olan ve mineral toprak yüzeyinden 100 cm içinde kaygan yüzeyler bulunan killi topraklar olmasıdır. Kurduğunda büzülmesi ve nemlendiğinde şişmesi önemli bir özelliğidir (USDA-NRCS, 1999). Nitekim tanımlanmasında profildeki morfolojik gözlemlerin etkin olduğu bu ordo seviyesinde daha fazla araştırmaya gerek bulunan konular mevcuttur. Ordo düzeyinde toprak sınıflandırması sonucu Kappa katsayıları eğitim seti için %38 test seti için %24 olarak hesaplanmıştır. Farklı alanlarda ve bölgeler ile karşılaştırıldığında sadece dijital verilerle sağlanan doğruluk literatürlere (Hengl vd., 2007; Collard vd., 2014; Camera vd., 2017; Zeraatpisheh vd., 2017; Taghizadeh-Mehrjardi vd., 2019; Rasaei vd., 2020) yakın bulunmuştur.

Makine öğrenimi algoritmalarının pedoloji bilimindeki amacı olan keşfetme aracı rolü etkin şekilde sürmektedir. Nitekim kurulan modellerdeki değişkenlerin önem seviyeleri, dikkatli şekilde toprak bilimciler tarafından yorumlanabildiğinde anlam kazanacaktır (Wadoux vd., 2020). Bu kapsamda modelde etkin olarak çevresel değişkenlerin göreceli önemlerini gösterir grafik Şekil 4.3’de verilmiştir. Jeolojik olarak çevresinde kireçtaşlarının hâkim olduğu çalışma alanında, toprakların oluşumunda kireçtaşının etkin olduğu görülmektedir. Nitekim ordo sınıflarının tahmininde en önemli değişken olarak Normalize Kireçli Sediment İndeksi belirlenmiştir. Bu indeks ana materyali temsil etmesi amacıyla veri setine dahil edilmiştir. Ovanın oluşumunda her ne kadar alüvyal bir birikimin sebep olduğu bilinse de aluviyal materyalin taşındığı havzada kireçtaşının yaygın olması bulunan sonuçları destekler niteliktedir. Nitekim Boettinger vd. (2008), Landsat uydu görüntülerinden ürettiği bu indisin kireçli ana materyal tanımlamalarında kullanılabileceğini bildirmiştir.

Taghizadeh-Mehrjardi vd. (2015), İran’daki USDA toprak gruplarını tahmin etmek için kil indeksi, karbonat indeksi, jips indeksi ve tuzluluk oranı gibi değişkenleri kullanmış, Landsat spektral verilerinin en yararlı çevresel değişkenler olduğu sonucuna varmışlardır. Mosleh vd. (2017), İran’da yaptıkları çalışmada, ordo düzeyinde toprakların sınıflandırılmasında kil ve karbonat indekslerinin etkin olduğunu bildirmiştir. Çalışmamızda göreceli önem seviyeleri grafiğinde kil ve

karbonat indeksleri de yüksek seviyede modele katkı sağladığı görülmektedir. Modele katkı anlamında alüvyal bir ovada topoğrafik etkilerin kısmen daha az bir etkiye sahip olduğu söylenebilir Farklı toprak ordolarının benzer tahmin edici değişken değerleri alması ve özellik uzayında çakışmalar sebebi ile bu durum oluşabilir (Hengl vd., 2007). Şekil 4.4 Toprak sınıflarının önemli bazı çevresel değişkenlere ait kutu grafikleri verilmiştir. Kırmızı noktaların ortalama değerleri, kalın çizginin medyanı gösterdiği bu grafikte özellikle Entisol ordosunun normalize kireçli sediment indeksi ve parlaklık indeksinde en yüksek ortalama ve medyan değerleri tespit edilmiştir. Sayısal toprak haritalamanın, geleneksel yaklaşıma göre getirdiği en büyük yenilik, bir sınıfın veya bir olgunun mekânsal bir ortamda oluşabilme olasılığını sağlam matematiksel esaslara dayandırarak ortaya koyabilmesidir. Şekil 4.5'te model sonucu her biri sınıfın her bir piksele ait olabilme olasılıklarını gösterir olasılık haritaları ve algoritmanın en yüksek olasılığa sahip sınıfa etiket atamasıyla oluşmuş en olası sınıf haritası bulunmaktadır. Entisol ve Mollisol ordolarının toprak etüdü ile oluşturulan detaylı toprak haritası ile bu sınıfların oluşma olasılığının 1'e yaklaştığı alanlar çok benzerlik göstermektedir. Özellikle Vertisolün çalışma alanının orta kesimlerinde yüksek olasılıklı oluşma durumları söz konusu olabilir. Ancak bu İnceptisol veya Mollisolden fazla olamadığı için olası sınıf olarak atanamamıştır. Bu çalışmada, Vertisol ordosu hariç olmak üzere, diğer 3 ordo için mevcut toprak haritası ile uyumlu sonuçlar olduğu sonucuna varılmıştır. Vertisol ordosunun tanımlanmasında saha morfolojik gözlemlerinin etkisine değinilmiştir. Bu kapsamda yüzeyde bünyeye bağlı morfolojik gözlemlerdeki farklılıkların çevresel değişken setimizin 30 metre mekânsal çözünürlüğüne yakalanamadığı ifade edilebilir. Bununla birlikte Vertisol ayırımında meydana gelebilecek uzman görüş farklılıkları da geleneksel olarak vertisol sınıfının tanımlanmasında zorlukları ortaya koyabilmektedir. Toprak sınıflandırma sistemlerinde taksonomik farklılıkların nesnel değerlendirilmesini ortaya koyabilmek için taksonomik mesafe kavramı özelinde çalışmalar sürdürülmektedir (Hole ve Hironaka; 1960; Sarkar vd., 1966; Michéli vd., 2016). Sayısal toprak haritalamada toprak sınıflarının haritalanması ve mekânsal tahmini sürecinde salt sınıflandırma doğruluğu yanında küresel olarak mevcut bulunan toprak profil verilerinin kullanımı yoluyla belirli sınıflandırma sistemlerinde hesaplanan taksonomik mesafeler kullanılabilmektedir (Minasny vd., 2010; Rossiter vd., 2017). Çalışmada ordo düzeyinde sınıflandırma sonucunda Vertisol sınıfının en çok İnceptisol ve Mollisol ordoları ile karıştığı görülmektedir (Çizelge 4.2 ve Şekil 4.5). Michéli vd., (2016),

Dünya genelinde mevcut toprak profil (Batjes, 2008; Batjes, 2009) verilerini kullanarak toprak özelliklerini ve Öklid mesafesini baz alarak oluşturdukları taksonomik mesafe hesaplamaları neticesinde Vertisol ordosunun taksonomik mesafe olarak en yakın Mollisol ordosuna ve 2. en yakın mesafe olarak Inceptisol ordosuna yakınlıklarını bildirmişlerdir. Tüm bu veriler doğrultusunda tarımsal ova alanlarında ve taksonomide benzer toprak türleri için toprak farklılıklarını yansıtabilecek yeni ortak değişkenlerin geliştirilmesi gerekmektedir.

4.1.2. Alt ordo düzeyinde toprakların sayısal olarak haritalanması

Örnekleme metodolojisine göre, alt ordo seviyesindeki toprak sınıfı haritalama birimlerinden Fluvent alt ordosu 81, Xerept alt ordosu, 270, Xerert alt ordosu 57 ve Xeroll alt ordosu 95 nokta ile temsil edilmiştir. Çok terimli lojistik regresyon ile model kurulurken Fluvent alt ordosu referans kategori olarak seçilmiştir. Model algoritmasına göre Fluvent alt ordosu referans kategorisi için model oluşturulmamıştır. R programında Alt ordo seviyesi için modelde “set.seed(1994)” kodu ile randomizasyonun alınan örneklerle sabitlenmesi sağlanmıştır.


Alt ordo düzeyinde toprak sınıflarının tahmini için kullanılan modele ait değişkenlerin katsayıları Çizelge 4.3’de, Alt ordo düzeyinde toprak sınıflarının doğruluk değerlendirmesi için hesaplanmış karışım matrisi Çizelge 4.4’de verilmiştir. Alt ordo düzeyinde toprakları sınıflandırmak amaçlı üretilen modelde önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.6’da ve önemli değişkenlere ait kutu grafikleri Şekil 4.7’de verilmiştir. Alt ordo düzeyinde toprakların en muhtemel sınıfa aitliklerini ve her bir alt ordonun oluşma olasılıklarının mekânsal haritaları Şekil 4.8’de verilmiştir.

Çizelge 4.3. Alt ordo düzeyi toprak sınıflarının tahmininde model değişken katsayıları


Alt ordo	Kesişim Noktası	Akış Birikim	Akış Doğrultusu	Bakı
Xerept	-17.04751	-0.002252442	0.01149155	-0.000621884
Xerert	22.98922	-0.009897912	0.01407479	-0.000653167
Xeroll	41.12525	-0.000368203	0.01601361	0.001821133
Alt ordo	Eğrilik	Eğim Uzunluğu	Planform Eğriliği	Profil Eğriliği
Xerept	0.185791699	0.025080602	0.06760291	-0.118446
Xerert	-0.002542061	0.162061337	-0.34203477	-0.3394905
Xeroll	0.061419646	0.002893187	-0.68567198	-0.7469916
Alt ordo	Akış Gücü İndeksi	Topografik Islaklık İndeksi	Yükseklik	Eğim (%)
Xerept	0.175365036	-0.15867757	-0.0028086	-0.13515852
Xerert	0.289792163	-0.22833917	-0.02506078	-0.27907571
Xeroll	-0.005877927	-0.05914618	-0.04208975	-0.09637122
Alt ordo	Hue indeks	Nor. Çıplak Toprak İnd.	Nor. Kireçli Sediment İnd.	Nor. Karbonat İnd.
Xerept	-25.5064	20.60762	-72.42343	3.877586
Xerert	18.09851	6.30483	-12.9895	12.140947
Xeroll	49.52942	19.81476	-13.77157	18.50278
Alt ordo	Nor. Demir (FeO+2) İnd.	Nor. Demir İnd.	Nor. Kil İnd.	Parlaklık İndeksi
Xerept	24.614503	-13.238154	28.631217	-45.284747
Xerert	11.212194	6.769938	-10.022885	9.774722
Xeroll	7.056581	-5.285126	-5.477786	-22.542145
Alt ordo	Nor. Bitki Fark İnd.	Satursayon İndeksi	Nor. Toprak Ayarlı Bitki İnd.	Üst Top.Tane Büy. İnd.
Xerept	6.423087	34.88444	9.634622	12.781926
Xerert	2.151009	-23.98082	3.226428	-2.210525
Xeroll	1.484124	-30.41556	2.226246	8.077768

Çizelge 4.4. Alt ordo düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi

		GÖZLEM					
		Eğitim Seti					
		Fluvent	Xerept	Xerert	Xeroll	Toplam	Kullanıcı
TAHMİN	Fluvent	16	5	0	2	23	%70
	Xerept	35	159	35	34	263	%61
	Xerert	0	4	2	1	7	%29
	Xeroll	3	14	8	34	59	%58
	Toplam	54	182	45	71	211	
	Üretici	%30	%88	%5	%48	Genel D.	%60
						Kappa	0.29=%29
						Test Seti	
	Fluvent	12	5	0	2	19	%64
	Xerept	14	70	10	11	105	%67
	Xerert	0	5	1	1	7	%15
	Xeroll	1	8	1	10	20	%50
	Toplam	27	88	12	24	93	
	Üretici	%45	%80	%9	%42	Genel D.	%62
						Kappa	0.30=%30



Şekil 4.6. Alt ordo düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi




Şekil 4.7. Alt ordo düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri

Çalışma alanında alt ordo sınıflandırması neticesinde alt ordo ayırımında etkin olan iklim parametrelerine dair alandaki mekânsal varyasyonunun düşük olduğu öngörülerek çevresel değişken üretilmediği için ordo ve alt ordo sınıflandırmalarında

görsel ve istatistiksel benzer sonuçlar bulunmaktadır. Nitekim benzer çalışmalarda da benzer sonuçlar alınmaktadır. Yarı kurak ve kurak küçük çalışma alanlarında iklimin varyasyonunun olmadığı bölgelerde bu beklenen bir durumdur (Mosleh vd., 2017). Çizelge 4.4. incelendiğinde alt ordo sınıflarının sayısal haritalanması sonucunda, modellemenin sınıflandırma genel doğruluğu eğitim seti için %60, test seti için %62 olarak belirlenmiştir. Özellikle modelleme test setinde düşme olmaması ve hatta yükseklik bulunması modelin sahaya özgü iyi bir tanımlama içerdiğinin bir göstergesi olmaktadır. Xerept alt ordosu çalışma alanında toprak etüt ve haritalamada sayısal toprak haritalama yaklaşımının kullanılabilirliğinde etkin sınır olan %70 doğruluğa sahip olduğunu göstermiştir. Alt ordo sınıflarının sayısal haritalanmasına yönelik oluşturulan model kapsamında modele katkıda bulunan değişkenlerin göreceli önemini gösterir grafik Şekil 4.6'da verilmiştir. Bu kapsamda Normalize kireçli sediment indeksi ve Parlaklık indeksi üst sıralardadır.

Şekil 4.8'de alt ordo seviyesinde toprakların oluşma olasılıklarını gösteren haritalar ve en olası sınıf haritası bulunmaktadır. Ordo sınıflarının dağılımı ile benzer bir görünüme sahip olduğu görülen alt ordo sınıflarının özellikle her iki sınıflandırma seviyesinde 4 kategori bulunması ve iklim varyasyonunun olmaması nedeniyle bu benzerliğin oluştuğu söylenebilir. Alt ordo ayırımında gözetilen toprak sıcaklık ve nem rejimleri alanda değişkenlik göstermemektedir. Alanda bulunan ordoların alt ordo tanımlarına bakıldığında toprak sıcaklığı rejimine sahip alt ordo bulunduran ordoların mevcudiyeti sebebiyle 3 alt ordo sıcaklık rejimi ile 1 alt ordo ise özellikle nehirlerin ve küçük akarsuların taşkın ovalarında, alüvyal fanlarında oluşan çoğunlukla Akdeniz iklimi olan bölgelerde bulunan fluvent ordosu olarak tanımlanmıştır. Değerlendirmeler sonucunda iklim değişkenliğinin olmadığı küçük çalışma alanlarında da çalışma sonuçlarımıza benzer sonuçlar alınmıştır (Mosleh vd., 2017).



Şekil 4.8. Alt ordo seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları

4.1.3. Büyük grup düzeyinde toprakların sayısal olarak haritalanması

Örnekleme metodolojisine göre, büyük grup seviyesindeki toprak sınıfı haritalama birimlerinden Calcixerept büyük grubu 109, Haploxerept büyük grubu 161, Haploxerert büyük grubu 57, Haploxeroll büyük grubu 95 ve Xerofluvent büyük grubu 81 nokta ile temsil edilmiştir. Çok terimli lojistik regresyon ile model kurulurken Calcixerept büyük grubu referans kategori olarak seçilmiştir. Model algoritmasına göre Calcixerept büyük grubu referans kategorisi için model oluşturulmamıştır. R programında Büyük grup seviyesi için modelde “set.seed(2023)” kodu ile randomizasyonun alınan örneklerle sabitlenmesi sağlanmıştır.


Büyük grup düzeyinde toprak sınıflarının tahmini için kullanılan modele ait değişkenlerin katsayıları Çizelge 4.5’de, Büyük grup düzeyinde toprak sınıflarının doğruluk değerlendirmesi için hesaplanmış karışım matrisi Çizelge 4.6’da verilmiştir. Büyük grup düzeyinde toprakları sınıflandırmak amaçlı üretilen modelde önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.9’da ve önemli değişkenlere ait kutu grafikleri Şekil 4.10’da verilmiştir. Büyük grup düzeyinde toprakların en muhtemel sınıfa aitliklerini ve her bir büyük grubun oluşma olasılıklarının mekânsal haritaları Şekil 4.11’de verilmiştir.

Çizelge 4.5. Büyük grup düzeyi toprak sınıflarının tahmininde model değişken katsayıları


Büyük grup	Kesişim Noktası	Akış Birikim	Akış Doğrultusu	Baki
Haploxerept	24.05346	0.004046569	0.012728704	-0.000567129
Haploxerert	35.78827	-0.005800126	0.014457166	-0.000631513
Haploxerol	65.99735	0.004671875	0.015373936	0.001093374
Xerofluvent	30.27134	0.005903112	-0.004959565	0.000681466
Büyük grup	Eğrilik	Eğim Uzunluğu	Planform Eğriliği	Profil Eğriliği
Haploxerept	-0.03902405	-0.2250064	-0.25234732	-0.2136714
Haploxerert	-0.05517593	-0.1764183	-0.68304483	-0.6278268
Haploxerol	0.04946737	0.1046792	-0.89820438	-0.9474751
Xerofluvent	-0.11953121	-0.1732789	0.03482091	0.1544679
Büyük grup	Akış Gücü İndeksi	Topografik Islaklık İndeksi	Yükseklik	Eğim (%)
Haploxerept	-0.14182402	0.18568777	-0.016975358	0.121578682
Haploxerert	0.1926029	0.12869737	-0.031062129	-0.005675196
Haploxerol	0.01113328	-0.05558244	-0.0624648	-0.09871946
Xerofluvent	0.2154293	-0.12965476	-0.004922486	0.087817967
Büyük grup	Hue indeks	Nor. Çıplak Toprak İnd.	Nor. Kireçli Sediment İnd.	Nor. Karbonat İnd.
Haploxerept	-91.26078	-14.155322	18.724613	-7.315545
Haploxerert	11.17736	-16.230107	26.425487	-4.796088
Haploxerol	68.65101	8.924549	8.081653	17.888313
Xerofluvent	-15.97302	-39.160332	96.824916	-31.506799
Büyük grup	Nor. Demir (FeO+2) İnd.	Nor. Demir İnd.	Nor. Kil İnd.	Parlaklık İndeksi
Haploxerept	-19.424	7.346221	-11.92826	36.4577
Haploxerert	-3.591319	12.087554	-23.77893	49.22929
Haploxerol	-6.885507	4.824657	-13.02231	13.71094
Xerofluvent	-41.423058	8.337072	-28.98612	99.6416
Büyük grup	Nor. Bitki Fark İnd.	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İnd.	Üst Top.Tane Büy. İnd.
Haploxerept	-8.139225	-28.85646	-12.208707	8.459461
Haploxerert	-3.517157	-35.35426	-5.275913	-15.05442
Haploxerol	-1.965371	-57.65784	-2.948025	8.825787
Xerofluvent	-14.612615	-34.03612	-21.918931	-22.461884

Çizelge 4.6. Büyük grup düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi

		GÖZLEM						
		Eğitim Seti						
		Calci xerept	Haplo xerept	Haplo xerert	Haplo xerol	Xero fluvent	Toplam	Kullanıcı
TAHMİN	Calcixerept	55	15	5	7	16	98	%55
	Haploxerept	15	77	22	18	10	142	%55
	Haploxerert	1	0	2	2	0	5	%40
	Haploxerol	11	10	8	36	2	67	%54
	Xero fluvent	6	6	2	2	28	44	%64
	Toplam	88	108	39	65	56	198	
	Üretici	%61	%72	%6	%56	%50	Genel D.	%56
		Kappa						0.41=%41
		Test Seti						
		Calci xerept	Haplo xerept	Haplo xerert	Haplo xerol	Xero fluvent	Toplam	Kullanıcı
	Calcixerept	13	8	3	0	3	27	%49
	Haploxerept	4	32	10	10	6	62	%52
	Haploxerert	0	1	0	1	0	2	%0
	Haploxerol	3	7	4	15	0	29	%52
	Xero fluvent	5	5	1	4	16	31	%52
	Toplam	25	53	18	30	25	76	
	Üretici	%52	%61	%0	%50	%64	Genel D.	%51
		Kappa						0.34=%34




Şekil 4.9. Büyük grup düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi



Şekil 4.10. Büyük grup düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri

Çok terimli lojistik regresyon sonucu toprakların büyük grup düzeyinde sınıflandırılma sonuçları Çizelge 4.6’da verilmiştir. Büyük grup düzeyinde eğitim setinde genel doğruluk %56, test setinde %51 olarak belirlenmiştir. Haploxerert büyük grubunun sınıflandırma doğrulukları çok düşük olmakla birlikte, Xerofluvent, Haploxerept ve Calcixerept büyük gruplarının eğitim ve test setlerinde genel doğrulukları %50 civarındır. Taghizadeh-Mehrjardi vd. (2019), İran’da 150 km²’lik Entisol ve Aridisol ordolarının mevcut olduğu alanda çok terimli lojistik regresyon kullanarak, büyük grup seviyesinde %34’lük bir genel doğruluk elde etmişlerdir. Büyük grup düzeyinde özellikle Xerofluvent büyük grubu parlaklık indeksi ortalama değerleri bakımından diğer büyük gruplardan farklılık göstermektedir. Makine öğrenme algoritmaları yanlış sınıflandırma hatasını en aza indirmeye çalışır ve bu nedenle tüm sınıflardaki hata eşit derecede önemlidir (Hastie vd., 2009). Ancak bu, toprak sınıfları arasında taksonomik ilişkilerin olduğu toprak sınıfları için geçerli değildir ve bu nedenle bazı hatalar diğerlerinden daha önemli olabilir ve sayısal toprak haritalamada bu hataların pedolojik yorumlamaları önemlidir (Taghizadeh-Mehrjardi vd., 2015). Çizelge 4.6 dikkate alındığında arazide Haploxerert ve Haploxeroll olarak tanımlanan eğitim ve test noktalarının model sınıflandırması sonucu Haploxerept sınıfına atandığı görülmektedir. Xerertler, serin, yağışlı ile kuru ve sıcak yazlar ile karakterize edilen Akdeniz iklimindeki Vertisollerdir. Haploxerertler, 100 cm derinlikte kalsik veya petrokalsik horizona veya duripana sahip olmayan Xerertler


olarak tanımlanır ve spesifik morfolojik görünlere sahip değildir. Haploxeroller, alt toprakta çok az gelişme ile karakterize edilen, az ya da çok serbest drenaja sahip Xeroll'lerdir. Genellikle, mollik epipedonun altında kambik bir alt teşhis horizonuna sahiptirler. Birçoğunda ikincil karbonatların biriktiği horizonlar mevcuttur. Kalsik horizonu bulunur ancak en azından yüzey horizonlarının bir kısmında karbonat bulunmamaktadır. Haploxereptler belirli bir derinlikte kireçli olan veya yüksek bir baz durumuna sahip olan, az çok serbestçe drene olan Xerept'lerdir. Bazı toprakların bir Bk veya kalsik horizonu vardır. Her 3 büyük grupta göz önüne alındığında üst hiyerarşide bulunan alt ordodan spesifik olarak belirli özelliklerce ayrılmayan büyük toprak grupları olarak kategorize edilebilecektir. Bu durumun pedolojik yorumlamaya da getireceği zorluk ön plana çıkmaktadır. Bu sebeple buradaki karışımın sebebi, alan ağırlıklı örneklem sonucu oluşmuş olan dengesiz veri seti dağılımı olabilecektir. Bununla birlikte çevresel değişkenlerin büyük toprak grubunu doğru tahmin etme sürecinde kritik öneminin vurgulanması gerekmektedir (Liu vd., 2016).



Şekil 4.11. Büyük grup seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları

4.1.4. Alt grup düzeyinde toprakların sayısal olarak haritalanması

Örnekleme metodolojisine göre, alt grup seviyesindeki toprak sınıfı haritalama birimlerinden Calcic Haploxerept alt grubu 29, Fluventic Haploxerept alt grubu 41, Petrocalcic Calcixerept alt grubu 25, Typic Calcixerept alt grubu 84, Typic Haploxerept alt grubu 61, Typic Haploxerol alt grubu 44, Typic Xerofluvent alt grubu 81, Udic Haploxerert alt grubu 57, Vertic Haploxerept alt grubu 30 ve Vertic Haploxerol alt grubu 51 nokta ile temsil edilmiştir. Çok terimli lojistik regresyon ile model kurulurken Calcic Haploxerept alt grubu referans kategori olarak seçilmiştir. Model algoritmasına göre Calcic Haploxerept alt grubu referans kategorisi için model oluşturulmamıştır. R programında Alt grup seviyesi için modelde “set.seed(1992)” kodu ile randomizasyonun alınan örneklerle sabitlenmesi sağlanmıştır. Alt grup düzeyinde toprak sınıflarının tahmini için kullanılan modele ait değişkenlerin katsayıları Çizelge 4.7 ve 4.8’de, Alt grup düzeyinde toprak sınıflarının doğruluk değerlendirmesi için hesaplanmış ve karışım matrisi Çizelge 4.9 ve 4.10’da verilmiştir. Alt grup düzeyinde toprakları sınıflandırmak amaçlı üretilen modelde önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.12’de ve önemli değişkenlere ait kutu grafikleri Şekil 4.13’ de verilmiştir. Alt grup düzeyinde toprakların en muhtemel sınıfa aitliklerini ve her bir Alt grubun oluşma olasılıklarının mekânsal haritaları Şekil 4.14. ve 4.15’de verilmiştir.



Şekil 4.12. Alt grup düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi

Çizelge 4.7. Alt grup düzeyi toprak sınıflarının tahmininde model değişken katsayıları

Alt grup	Kesişim Noktası	Akış Birikim	Akış Doğrultusu	Baki
Fluventic Haploxerept	-45.68955	-0.02030859	0.000223612	0.003484814
Petrocalcic Calcixerept	-64.268795	-0.006992987	-0.006061749	0.005427768
Typic Calcixerept	-27.034294	-0.014731464	-0.00865089	0.003362121
Typic Haploxerept	11.740481	-0.004043717	0.002819384	0.002046668
Typic Haploxerol	-15.668188	0.000131763	0.005492233	0.005832903
Typic Xerofluvent	-22.378709	-0.000407746	-0.017570694	0.006234546
Udic Haploxerert	4.981476	-0.009630702	-0.000643806	0.003784206
Vertic Haploxerept	49.505655	-0.014638124	0.005706991	-0.000123235
Vertic Haploxerol	73.38097	-0.041299298	0.004122463	0.008343226
Alt grup	Eğrilik	Eğim Uzunluğu	Planform Eğriliği	Profil Eğriliği
Fluventic Haploxerept	0.05914313	-0.32629285	-1.0941331	-1.15327595
Petrocalcic Calcixerept	-0.27017683	-0.01975467	0.43311251	0.70327911
Typic Calcixerept	0.04656772	-0.18046306	-0.04939529	-0.09597336
Typic Haploxerept	-0.2068797	0.34315171	-0.3981571	-0.19129349
Typic Haploxerol	-0.05714609	-0.39494059	-1.32057137	-1.26341434
Typic Xerofluvent	-0.48842203	-0.10727077	0.16125793	0.64969452
Udic Haploxerert	-0.28440044	-0.06577085	-0.71773573	-0.43331933
Vertic Haploxerept	-0.0851982	-0.37147787	0.32431565	0.40951873
Vertic Haploxerol	-0.02679778	-0.69019573	-0.88695729	-0.86015555
Alt grup	Akış Gücü İndeksi	Topografik Islaklık İndeksi	Yükseklik	Eğim (%)
Fluventic Haploxerept	-0.32743469	1.637897	0.035932473	0.5732979
Petrocalcic Calcixerept	-0.82959209	1.0340039	0.058590429	0.5704049
Typic Calcixerept	-0.09249032	0.9707057	0.016185185	0.2391279
Typic Haploxerept	-0.84871267	0.8493803	-0.017184503	0.459448
Typic Haploxerol	-0.93537689	1.724118	-0.001089706	0.8154641
Typic Xerofluvent	-0.8774453	1.3310064	0.018133562	0.7263054
Udic Haploxerert	-0.57496388	1.3875069	-0.01734421	0.5018607
Vertic Haploxerept	-0.60452378	1.1125947	-0.06732732	0.3613902
Vertic Haploxerol	-0.34961475	1.4168076	-0.100132562	0.5337664

Çizelge 4.8. Alt grup düzeyi toprak sınıflarının tahmininde model değişken katsayıları


Alt grup	Hue indeks	Nor.Çıplak Toprak İnd.	Nor. Kireçli Sediment İnd.	Nor. Karbonat İnd.
Fluventic Haploxerept	-4.7553071	0.1934356	5.812448	-8.6584398
Petrocalcic Calcixerept	-0.872216	3.6894588	31.404132	4.484112
Typic Calcixerept	-0.8697517	20.5556019	-2.940981	11.6399774
Typic Haploxerept	-4.302609	-9.6891256	9.063577	-0.3642149
Typic Haploxerol	17.673929	26.6525351	-13.177428	3.1688287
Typic Xerofluvent	-1.8004858	-19.352134	42.14737	-12.3054838
Udic Haploxerert	-1.9628448	3.1464443	7.878564	-3.708358
Vertic Haploxerept	0.3939951	16.7097881	-8.196052	20.5006298
Vertic Haploxerol	-1.049652	8.8526781	-1.618749	4.1283042
Alt grup	Nor. Demir (FeO+2) İnd.	Nor. Demir İnd.	Nor. Kil İnd.	Parlaklık İndeksi
Fluventic Haploxerept	-2.08403756	-8.9670376	-11.722717	-9.853235
Petrocalcic Calcixerept	-1.43066886	0.9652949	3.439856	-10.841721
Typic Calcixerept	10.44353752	-8.9246732	8.130038	-23.248009
Typic Haploxerept	-0.06628756	9.4603654	8.029365	9.676479
Typic Haploxerol	-15.15340403	-23.4102833	-37.386178	-7.186672
Typic Xerofluvent	4.77089963	6.9651544	13.539639	14.08881
Udic Haploxerert	5.53732162	-6.7685459	-2.835798	6.148395
Vertic Haploxerept	1.83324489	3.5515269	9.365358	5.618369
Vertic Haploxerol	29.05839969	-4.7762494	27.942845	11.033678
Alt grup	Nor. Bitki Fark İnd.	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İnd.	Üst Top.Tane Büy. İnd.
Fluventic Haploxerept	-0.4812121	-14.8099802	-0.7218295	-5.3727407
Petrocalcic Calcixerept	4.2799976	-1.7306095	6.4199934	2.5892338
Typic Calcixerept	5.8315397	18.5369844	8.7473261	8.7106855
Typic Haploxerept	-2.4022964	15.7648517	-3.6034383	-0.3520628
Typic Haploxerol	2.1903156	-19.0642773	3.2854861	2.1672261
Typic Xerofluvent	-2.0505466	14.3520483	-3.0758235	-8.0067005
Udic Haploxerert	1.3421686	-0.4629885	2.0132394	-3.6147833
Vertic Haploxerept	3.6837582	25.497186	5.5256375	14.13204
Vertic Haploxerol	3.3655574	-6.9006912	5.0483381	2.6354837

Çizelge 4.9. Alt grup düzeyinde toprak sınıflandırma sonuçlarının eğitim seti karışım matrisi


		GÖZLEM											
		Eğitim Seti											
		Cal. Haploxerept	Flu. Haploxerept	Petr. Calcixerept	Typ. Calcixerept	Typ. Haploxerept	Typ. Haploxerol	Typ. Xerofluvent	Ud. Haploxerert	Ver. Haploxerept	Ver. Haploxerol	Top.	Kullanıcı
TAHMİN	Cal. Haploxerept	3	0	0	0	2	1	1	1	0	1	9	%34
	Flu. Haploxerept	0	12	1	3	0	2	0	1	0	0	19	%64
	Petr. Calcixerept	0	0	8	2	0	1	1	0	0	0	12	%67
	Typ. Calcixerept	3	8	2	41	6	2	12	12	2	5	93	%45
	Typ. Haploxerept	5	1	0	1	25	2	5	4	2	2	47	%54
	Typ. Haploxerol	4	1	0	2	3	15	0	5	1	1	32	%47
	Typ. Xerofluvent	1	4	5	5	5	3	34	3	0	0	60	%57
	Ud. Haploxerert	3	1	0	4	3	5	4	11	1	2	34	%33
	Ver. Haploxerept	0	0	0	2	0	0	0	0	11	3	16	%69
	Ver. Haploxerol	1	0	0	3	3	3	0	3	2	15	30	%50
	Toplam	20	27	16	63	47	34	57	40	19	29	175	
	Üretici	%15	%45	%50	%66	%54	%45	%60	%28	%58	%52	Genel D.	%50
												Kappa	0.42=%42

Çizelge 4.10. Alt grup düzeyinde toprak sınıflandırma sonuçlarının test seti karışım matrisi


		GÖZLEM											
		Test Seti											
		Cal. Haploxerept	Flu. Haploxerept	Petr. Calcixerept	Typ. Calcixerept	Typ. Haploxerept	Typ. Haploxerol	Typ. Xerofluvent	Ud. Haploxerert	Ver. Haploxerept	Ver. Haploxerol	Top.	Kullanıcı
TAHMİN	Cal. Haploxerept	0	0	0	1	1	0	1	0	0	0	3	%0
	Flu. Haploxerept	0	5	2	0	2	1	3	1	0	0	14	%36
	Petr. Calcixerept	0	0	3	2	0	0	0	0	0	0	5	%60
	Typ. Calcixerept	2	3	2	10	3	0	7	3	3	2	35	%29
	Typ. Haploxerept	2	1	0	1	4	2	0	5	4	1	20	%20
	Typ. Haploxerol	3	2	1	2	1	4	2	2	0	1	18	%23
	Typ. Xerofluvent	0	3	1	1	2	1	11	1	0	0	20	%56
	Ud. Haploxerert	1	0	0	2	1	1	0	3	1	2	11	%28
	Ver. Haploxerept	0	0	0	2	0	0	0	1	3	0	6	%50
	Ver. Haploxerol	1	0	0	0	0	1	0	1	0	16	19	%85
	Toplam	9	14	9	21	14	10	24	17	11	22	58	
	Üretici	%0	%36	%34	%48	%29	%40	%46	%18	%28	%73	Genel D.	%40
	Kappa												0.31=%31



Şekil 4.13. Alt grup düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri



Şekil 4.14. Alt grup seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları



Şekil 4.15. Alt grup seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları

Çok terimli lojistik regresyon algoritması ile alt grup seviyesinde toprakların sayısal haritalanması sonuçlarına göre çalışma alanında genel doğruluk seviyesi eğitim setinde %50 test setinde ise %40 olarak belirlenmiştir. Şekil 4.12’de alt grup düzeylerinin sınıflandırılmasına yönelik modele katkı sunan değişkenlerin göreceli önemi dikkate alındığında en önemli değişken Normalize kil indeksi olarak belirlenmiştir. Alt grup düzeyinde Calcic Haploxerept alt grubunun eğitim ve test setlerinde düşüş ve farklı sınıflara karışma düzeyleri görülmektedir. Calcic Haploxerept için USDA, NRCS (1999) Toprak sınıflandırma sisteminde gerekli olan birkaç spesifik sınıflandırma sebebinin model tarafından yakalanamadığı görülmektedir. Calcic Haploxerept için bir calcic horizon varlığı veya ikincil karbonat birikimi gibi sebepler aranırken en çok karıştığı alt gruplar olan Typic Calcixerept Typic Haploxerept için bu sınırlamalar yoktur. Özellikle profil gelişimi boyunca morfolojik gözleme dayalı alt grup ayrımlarında düşük doğruluk değerlerinin eldesi önemli bir durumdur. Nitekim buna yönelik profillerden elde edilen spektrometrik veya x-ray floresans cihazları ile elde edilen veriler sınıflandırma doğruluğunu artırabilmek amaçlı kullanılabilir (Vasques vd., 2014; Poppiel vd., 2019; Dotto vd., 2020; Asgari vd., 2020; Gozukara vd., 2021). Mosleh vd., (2017), çok terimli lojistik regresyon ile toprak sınıflarının tahmini için yaptıkları çalışmada, alt grup ve familya seviyelerinin doğruluklarında önemli bir düşüş eğilimi gözlemlendiğini bildirmişlerdir.

4.1.5. Seri düzeyinde toprakların sayısal olarak haritalanması

Örnekleme metodolojisine göre, Seri seviyesindeki toprak sınıfı haritalama birimlerinden Akçay serisi 6, Bayat serisi 30, Büyükgökçeli serisi 35, Çayakıntısı serisi 18, Diklitaş serisi 38, Hıdırlık serisi 7, İslamköy serisi 65, Karaağaçlar serisi 19, Kırbagları serisi 5, Kırlar serisi 17, Kuleönü serisi 26, Kuştepesi serisi 29, Onaç serisi 8, Orkav serisi 51, Pazararkası serisi 19, Pembeli serisi 50, Serenli serisi 44, Yakabağları serisi 13, Yenibağlar serisi 17, Yeşilova serisi 6 nokta ile temsil edilmiştir. Çok terimli lojistik regresyon ile model kurulurken Akçay serisi referans kategori olarak seçilmiştir. Model algoritmasına göre Akçay serisi referans kategorisi için model oluşturulmamıştır. R programında seri seviyesi için modelde “set.seed(1994119)” kodu ile randomizasyonun alınan örneklerle sabitlenmesi sağlanmıştır. Seri düzeyinde toprak sınıflarının tahmini için kullanılan modele ait

değişkenlerin katsayıları Çizelge 4.11, 4.12 ve 4.13’de, Seri düzeyinde toprak sınıflarının doğruluk değerlendirmesi için hesaplanmış karışım matrisi Çizelge 4.14 ve 4.15’de verilmiştir. Seri düzeyinde toprakları sınıflandırmak amaçlı üretilen modelde önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.17’de ve önemli değişkenlere ait kutu grafikleri Şekil 4.16’da verilmiştir. Seri düzeyinde toprakların en muhtemel sınıfa aitliklerini ve her bir serinin oluşma olasılıklarının mekânsal haritaları Şekil 4.18 ve 4.19’da verilmiştir.



Çizelge 4.11. Seri düzeyi toprak sınıflarının tahmininde model değişken katsayıları

Seri	Kesim Noktası	Akış Birikim	Akış Doğrultusu	Bakı	Akış Gücü İndeksi	Topografik Islaklık İndeksi	Yükseklik	Eğim (%)
Bayat	1.2107631	-0.003395143	0.00667077	0.005839479	-0.17871881	0.35103348	-0.00297121	0.111133389
Buyukgokceli	-1.1244435	-0.002122256	0.006598827	0.005747194	1.36914724	-0.80744592	0.004077558	0.224068679
Cayakintisi	0.2584981	-0.00012694	0.004573186	0.005847709	-0.71474442	0.5278793	-0.007701082	0.619011173
Dikilitas	1.0564584	-0.016572145	0.007591699	0.005032874	0.38816348	0.66768575	-0.007613353	0.391751396
Hidirlık	-0.3993318	-0.003108211	0.003450599	0.001189437	0.72762179	-1.53275308	0.010706067	-0.323661297
İslamkoy	0.8617944	-0.018668806	-0.00859598	0.003747953	0.58538694	-0.01114698	0.000934232	0.053747789
Karaagac	-0.1937851	-0.010979956	0.002751565	0.005594436	0.90694736	-0.46794111	0.002071837	0.120874029
Kirbaglar	-0.1992828	0.004438122	-0.017463289	0.00489378	-0.26074776	-0.34815744	-0.000284379	0.402017908
Kırlar	-0.395498	0.002349685	-0.014343576	0.005135927	0.99807387	-0.12935507	-0.000647	0.477506235
Kuleonu	1.5448358	-0.002848159	-0.001609485	0.007964426	-0.11126366	0.34394342	-0.001688114	0.110787066
Kustepe	0.518472	0.00351571	0.003405097	0.002567615	-0.12106752	0.02006353	-0.00119262	0.289249438
Onac	-0.4676426	0.002704644	-0.022063759	0.00395017	1.19696389	-0.60216163	0.005612652	-0.088361893
Orkav	1.9654269	-0.002902924	0.000649288	0.006070631	-0.09920174	0.35022374	-0.004574288	0.245790946
Pazararkasi	-2.2112684	-0.002536927	-0.003771753	0.000135274	1.58918134	-2.23475921	0.020754975	-0.638629784
Pembeli	-0.3352922	0.001641429	-0.025785715	0.005961192	0.24559174	-0.14748056	-0.000389623	0.323882094
Serenli	0.3507805	0.001152693	0.010094922	0.007273507	0.05578964	0.03808361	-0.002062161	0.313323306
Yakabaglar	-1.115005	0.001708182	-0.024734827	0.002879306	1.9086487	-1.79105248	0.01237281	-0.008750801
Yenibaglar	-0.5222698	-4.59678E-05	0.002630667	-0.003670641	0.84284725	-1.32505946	0.011433481	-0.300515603
Yesilova	-0.1086425	0.002100942	0.002901051	0.004979192	0.26157097	0.43401921	-0.006602026	0.646929608

Çizelge 4.12. Seri düzeyi toprak sınıflarının tahmininde model değişken katsayıları

Seri	Eğrilik	Eğim Uzunluğu	Planform Eğriliği	Profil Eğriliği	Hue indeks	Nor. Çıp.Top. İnd.	Nor. Kireçli Sed.İnd.	Nor.Karbonat İnd.
Bayat	0.08575605	0.06078246	1.51874712	1.43299097	0.092995903	1.10732133	0.03974615	1.488995464
Buyukgokceli	0.08450697	-0.19777784	0.20861978	0.12411292	-0.165939403	-1.25658039	-0.51834571	-1.304159004
Cayakintisi	-0.05162216	-0.16316353	-0.84891597	-0.79729387	-0.036696212	-0.78870518	-0.37878064	-0.195903744
Dikilitas	0.06882002	-0.49712767	0.60585884	0.53703869	-0.047861215	-0.83272953	-1.15136988	-0.88512286
Hidirlik	0.32017886	0.89361755	0.12537705	-0.19480173	0.010828613	-0.14669585	0.06483679	0.102845706
Islamkoy	0.71410218	-0.22479591	0.80837869	0.09427637	0.064093912	1.68902547	1.40134075	1.005249743
Karaagac	0.54002415	0.22210199	-1.44401392	-1.98403785	-0.022087319	-0.14646856	-0.11144981	-0.129487674
Kirbaglar	-0.19454509	-0.23414397	0.47973007	0.67427503	-0.008337383	0.08189941	0.20145171	-0.091955705
Kırlar	0.04147459	-0.68026147	-0.23304118	-0.2745155	0.021220344	0.40552596	0.80435843	0.633575887
Kuleonu	0.3406883	-0.14017338	-0.4269563	-0.76764434	0.058211526	-1.63816547	-2.68012117	0.658360765
Kustepe	0.25723542	-0.21795613	0.45640532	0.19916961	0.054139326	-0.99874693	-1.19224452	-0.575195339
Onac	-0.02259515	-1.26645735	-0.32916964	-0.30657446	0.014806367	0.29114496	0.34755562	0.25860205
Orkav	0.29624378	-0.3746929	1.80050869	1.50426484	-0.03263285	1.51536491	0.83181383	0.110133961
Pazararkasi	-0.05793968	0.74290553	0.55172537	0.60966491	0.059557324	0.66279332	0.58681926	0.246743538
Pembeli	0.12243245	0.29205564	0.91370581	0.79127343	-0.045822838	-1.25148945	0.58037858	-0.552920128
Serenli	0.08708135	0.16688642	-1.04091557	-1.12799665	0.067485802	0.30213396	-1.30775266	-0.47423768
Yakabaglar	0.2339093	-0.28459553	-1.1084318	-1.34234129	-0.032372312	0.21354925	0.72792449	-0.277457431
Yenibaglar	-0.31060744	0.39959469	0.5514454	0.86205284	0.01367612	0.49790246	1.00029428	0.191419767
Yesilova	-0.17657829	-0.80518291	0.05582943	0.23240767	-0.011726515	0.19438242	0.26026795	-0.001250279

Çizelge 4.13. Seri düzeyi toprak sınıflarının tahmininde model değişken katsayıları

Seri	Normalize Demir (FeO+2) İndeksi	Normalize Demir İndeksi	Normalize Kil İnd.	Parlaklık İndeksi	Nor. Bitki Fark İn.	Satursayon İndeksi	Nor.Top. Ay. Bitki İn.	Üst Top. Tane Büy. İn.
Bayat	0.90144267	0.36755678	-0.33604062	0.262809778	-1.567168503	1.953301592	-2.35075267	0.999370055
Buyukgokceli	-1.38977381	-0.04228287	0.44728522	-0.443691983	1.816805136	-1.791638801	2.72520757	-0.856606574
Cayakintisi	-1.09067872	0.59014687	0.63986066	-0.051103075	1.101573578	-0.342834917	1.65236026	-0.132419107
Dikilitas	-0.50492166	-0.04679845	0.17146822	0.024941791	0.722439163	-1.160048586	1.08365869	-0.597813296
Hidirlik	-0.35981391	0.24802778	0.04823698	-0.078588011	0.155284254	0.12785534	0.23292636	0.067474499
Islamkoy	1.01864859	-0.6909923	0.44303952	0.241473952	0.125918671	1.960791623	0.18887811	0.67772613
Karaagac	-0.28612	0.01849384	-0.12365309	-0.016412353	0.146616931	-0.174578163	0.21992532	-0.090662614
Kirbaglar	0.33756323	-0.17233876	0.02228197	-0.021568441	-0.135001498	-0.077118589	-0.20250226	-0.063326899
Kirlar	0.28306665	0.22338329	-0.12087878	0.180401291	-0.608337105	1.032847741	-0.91250563	0.42366004
Kuleonu	0.57102691	2.28749339	-1.41595691	0.45756743	-4.206685784	1.123305089	-6.3100286	0.427617541
Kustepe	-0.72167353	0.42516216	-0.1695541	0.035399195	0.145465536	-0.812277616	0.2181982	-0.390146621
Onac	-0.28949293	-0.03646251	-0.07963774	-0.07179924	0.229771408	0.30483775	0.34465718	0.177509432
Orkav	2.52435337	-1.39833176	0.68218818	0.311111421	-0.40820661	-0.277699137	-0.61231002	0.068298007
Pazararkasi	0.16512556	-0.413192	-0.85167849	-0.459965399	-0.591418542	0.039671042	-0.88712787	0.174195254
Pembeli	-1.26792531	0.69719984	1.22161879	0.132436782	1.709041891	-0.304770466	2.56356285	-0.370003668
Serenli	-0.58230515	-0.77229731	-1.23292889	-0.17380001	0.123550115	-1.157116199	0.18532547	-0.314416662
Yakabaglar	0.01140415	-0.48119747	0.16631208	-0.213144591	0.621696253	-0.424726455	0.93254438	-0.188395983
Yenibaglar	0.29089389	-0.30591859	0.21142583	0.033490932	0.231428204	0.376272221	0.34714239	0.12502989
Yesilova	0.2514975	-0.19434617	0.05986953	-0.005831333	0.008689781	0.004530428	0.01303462	-0.001972648

Çizelge 4.14. Seri düzeyinde toprak sınıflandırma sonuçlarının eğitim seti karışım matrisi


		GÖZLEM																					
		Eğitim Seti																					
		Akçay	Bayat	Büyükgoççeli	Çayakıntısı	Dikilitaş	Hıdırlık	İslamköy	Karaağaçlar	Kırbağlar	Kırlar	Kuleönü	Kuştepesi	Onaç	Orkav	Pazararkası	Pembeli	Serenli	Yakabağlar	Yenibağlar	Yeşilova	Toplam	Kullanıcı
TAH MİN	Akçay	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
	Bayat	1	6	0	1	2	0	3	1	0	0	2	0	0	3	0	0	0	0	0	0	19	%32
	Büyükgoççeli	0	0	8	4	1	0	3	0	0	0	0	2	1	0	1	2	4	1	1	1	29	%28
	Çayakıntısı	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	2	%0
	Dikilitaş	0	0	1	0	4	1	0	1	0	1	0	0	0	1	0	0	3	0	0	0	12	%34
	Hıdırlık	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
	İslamköy	1	7	7	2	6	1	28	4	0	3	3	7	4	13	4	4	8	1	3	1	107	%27
	Karaağaçlar	0	0	1	0	1	0	0	1	0	0	0	0	0	0	0	1	1	0	1	0	6	%17
	Kırbağları	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
	Kırlar	0	0	0	0	0	0	2	0	1	2	1	0	0	1	0	1	0	0	0	0	8	%25
	Kuleönü	0	2	0	1	1	0	3	0	0	0	11	2	0	3	0	1	2	0	0	0	26	%43
	Kuştepesi	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	%0
	Onaç	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	%0
	Orkav	1	3	1	0	4	0	2	0	1	0	0	3	1	9	0	2	3	0	0	0	30	%30
	Pazararkası	1	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	2	0	8	%63
	Pembeli	0	1	1	0	1	1	2	3	0	2	0	1	0	2	0	15	2	0	1	0	32	%47
	Serenli	1	2	4	2	5	0	4	0	1	2	3	6	0	1	0	5	9	0	0	0	45	%20
	Yakabağları	0	0	0	0	0	0	0	0	0	1	0	0	1	0	1	3	1	7	1	0	15	%47
	Yenibağlar	1	0	2	0	1	0	0	1	0	0	0	0	0	0	1	1	1	0	2	1	11	%19
	Yeşilova	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
	Toplam	6	21	25	10	27	3	47	11	3	11	20	22	7	33	12	35	35	9	11	4	107	
	Üretici	%0	%29	%32	%0	%15	%0	%60	%10	%0	%19	%56	%0	%0	%28	%42	%43	%26	%78	%19	%0	Genel D.	%31
	Kappa																						0.23= %23

Çizelge 4.15. Seri düzeyinde toprak sınıflandırma sonuçlarının test seti karışım matrisi


		GÖZLEM																					
		Test Seti																					
		Akçay	Bayat	Büyükgoçeli	Çayakıntısı	Dikilitaş	Hıdırlık	İslamköy	Karaağaçlar	Kırbağlar	Kırlar	Kuleönü	Kuştepesi	Onaç	Orkav	Pazararkası	Pembeli	Serenli	Yakabağlar	Yenibağlar	Yeşilova	Toplam	Kullanıcı
TAH MİN	Akçay	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
	Bayat	0	1	1	0	1	0	2	0	0	0	1	0	0	1	1	2	0	0	0	10	%10	
	Büyükgoçeli	0	0	3	1	2	0	1	0	0	0	0	0	0	0	1	2	1	0	1	12	%25	
	Çayakıntısı	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	Dikilitaş	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0	0	0	1	0	5	%20	
	Hıdırlık	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	İslamköy	0	4	4	2	2	1	10	4	0	1	2	1	1	8	1	2	0	0	1	1	45	%22
	Karaağaçlar	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	Kırbağları	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	Kırlar	0	0	0	0	0	0	0	0	0	2	0	0	0	1	0	0	0	0	0	3	%67	
	Kuleönü	0	2	0	2	0	0	0	1	0	0	4	1	0	2	0	0	1	0	1	0	14	%29
	Kuştepesi	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	Onaç	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	Orkav	0	1	0	0	1	0	1	0	0	1	0	0	0	4	0	0	0	0	0	8	%50	
	Pazararkası	0	0	0	0	0	2	0	0	0	0	0	0	0	0	2	1	0	0	0	5	%40	
	Pembeli	0	1	1	0	2	0	3	1	2	0	0	0	0	0	1	7	1	3	0	22	%32	
	Serenli	0	0	0	2	1	0	0	1	0	0	0	2	0	3	1	1	3	0	2	16	%19	
	Yakabağları	0	0	0	0	0	0	0	0	0	2	0	0	0	0	1	2	0	0	0	5	0	
	Yenibağlar	0	0	0	0	0	1	0	1	0	0	0	2	0	0	0	0	0	0	1	5	%20	
	Yeşilova	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN	
	Toplam	0	9	10	8	10	4	18	8	2	6	6	7	1	18	7	15	9	4	6	39		
	Üretici	NaN	%12	%30	%0	%10	%0	%56	%0	%0	%34	%67	%0	%0	%23	%29	%47	%34	%0	%17	0	Genel D.	%26
		Kappa																				0.18= %18	




Şekil 4.16. Seri düzeyi sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri



Şekil 4.17. Seri düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi



Şekil 4.18. Seri seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları



Şekil 4.19. Seri seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları

Amerikan toprak sınıflandırma sisteminde pedolojik ayrımlara dayanan ve arazi kullanımı ve yönetimine dair en detaylı bilgileri verebilen sınıflandırma düzeyi seride

sınıflandırma genel doğruluğu eğitim seti için %31 test seti için %26 olarak belirlenmiştir. Birçok çalışma da test setlerinde görülen doğruluk düşüşleri modelin aşırı uymuş olabileceği şeklinde yorumlanabilmektedir. En yüksek ordo düzeyinden en düşük seviyesi olan seriye kadar eğitim ve test setleri arasında aşırı doğruluk farklılıkları görülmemiştir. Buradan değişken seçiminin isabetli yapılmış olduğu yorumu yapılmıştır. Bununla birlikte özellikle çok az gözleme sahip belli seriler karışım matrisinde “NaN” değeri almıştır. Bu durum 0’ a bölünme ile ilgili bir durumdur. Bu serilerde oluşma olasılıkları belli pikseller için hiç olmayabilir. Sharififar vd. (2019), bir bölgedeki gözlemlenen toprak sınıflarındaki dengesiz veri sayısının, az sayıda olan sınıflarının eksik tahmin edilmesine ve tahmin haritalarında çoğunluk sınıflarının fazla tahmin edilmesine neden olabileceğini bildirmiştir. Bu gibi durumlara yönelik ek gözlemler veya veri içinde yeniden örneklem gibi makine öğrenme algoritmalarında veri bilimi alanında etkin olarak kullanılan yöntemler kullanılabilir. Diğer toprak düzeylerinden farklı olarak seri düzeyinde sınıflandırma da modellemede göreceli önemi yüksek çevresel değişkenler bitki fark indeksleri olmuştur. Ancak yine bu önem sırasında normalize kireçli sediment ve çıplak toprak indeksleri de önemli bulunmuştur. Nitekim örnekleme noktaları seri bazında, farklı arazi kullanımlarına denk gelmiş olabilecektir. Burada bir kış görüntüsü seçilmesine rağmen bu farklılığın oluşuyor olması, bitki örtüsünün doğal dağılımından ileri gelmediği düşünülmektedir. Nitekim, Temel bileşenler analizi sonucuna göre bitki indeksleri ile toprak organik karbonu ile toprak kimyasal özellikleri arasında faktörlenebilir ilişkiler belirlenmiştir. Bu sebeple buradaki bitki örtüsünün etkinliği arazi kullanımına bağlanabilecektir. Böyle olsa bile uzun yıllardır tarımsal faaliyetlerin süregeldiği çalışma alanında veya çalışma alanımıza benzer alanlarda bu durumun önemle dikkate alınması gerekmektedir. Bitki indekslerinin göreceli öneminin yüksekliğinin yanında özellikle topoğrafik ıslaklık indeksi ve akış gücü indekslerinin seri sınıflandırmasında etkin öneme sahip olduğu görülmektedir. Topoğrafyanın, toprak sınıflandırma sisteminde alt kategorilerinde etkili olduğu bilinmektedir. Nitekim seri düzeyinde bu etkiyi görmemiz alüvyal ovalarda topoğrafik faktörlerin yeterli mekânsal çözünürlüğe sahip olması durumunda etkili bir şekilde kullanılabileceğini ortaya koyması açısından önemli bir bulgu olduğu düşünülmüştür. Özellikle 30 metrelik çözünürlüğe sahip veri setimizde planform eğriliği ve profil eğriliği parametreleri, suyun akışını yönlendirmesi gibi etkilere sahip olduğundan profil gelişimine ve profil tanımlarken dikkate alınan hususlarla doğrudan ilişkilidir.

Bu sebeple sınıflandırma sisteminin alt kategorilerinde hâkim düz bir alanda da olsa topoğrafik faktörlerin önemini vurgulamak gereklidir.

Sınıflandırma doğruluklarında özellikle eğim ve yükseklikle ayrımı yapılabilen Pembeli, Yakabağları ve Pazararkası serilerinin eğitim setinde yüksek doğrulukları mevcuttur. Çalışma alanının orta kesiminde yer alan ve en fazla alana sahip seri olan İslamköy serisinde de doğruluk seviyeleri eğitim setinde %60, test setinde %56 olarak belirlenmiştir.

Tüm bu değerlendirmeler ışığında seri seviyesinde belirlenen doğruluk sayısal haritalamanın bu günkü gelişimine uygun olduğu görülmüştür.

Genel doğruluklar dikkate alındığında Subbaruyalu vd. (2013), Amerika’da etkin şekilde kullanılan bir veri seti olan toprak etüdü coğrafi veri tabanı (SSURGO)’nda mevcut olan serileri farkı makine öğrenme algoritmaları ile sayısal olarak haritaladıklarında %23-31 arasında genel doğruluk değerleri elde etmişlerdir.

Seri tanımının sahada profil gözlemleri ve burgularla arazi kontrolleri yapıldığı göz önünde bulundurulduğunda, tanımlamada pedojenezi etkileyen en önemli toprak oluşum faktörlerinin ana materyal ve topoğrafya olduğu bilinmektedir. Modelleme ile serilerin tahmininde en etkili çevresel değişkenlerin ana materyal ve topoğrafik çevresel değişkenler olması bu genel kanıyı desteklemektedir. Bu durumun sayısal haritalama yaklaşımının doğru çevresel değişken veri setlerinin oluşturulabilmesi neticesinde etkin şekilde doğru dijital toprak haritalarının oluşturulmasına olanak sağlayacağı ifade edilebilir.

4.1.6. FAO-WRB sınıflandırma düzeyinde toprakların sayısal haritalanması

Örnekleme metodolojisine göre, FAO-WRB 2. seviyesindeki toprak sınıfı haritalama birimlerinden Calcaric Fluvisol sınıfı 81, Chromic Cambisol sınıfı 17, Eutric Cambisol sınıfı 114, Eutric Vertisol sınıfı 57, Haplic Calcisol sınıfı 84, Mollic Fluvisol sınıfı 95, Petric Calcisol sınıfı 25, Vertic Cambisol sınıfı 30 nokta ile temsil edilmiştir. Çok terimli lojistik regresyon ile model kurulurken Calcaric Fluvisol sınıfı referans kategori olarak seçilmiştir. Model algoritmasına göre Calcaric Fluvisol sınıfı referans

kategorisi için model oluşturulmamıştır. R programında Alt grup seviyesi için modelde “set.seed(199241)” kodu ile randomizasyonun alınan örneklerle sabitlenmesi sağlanmıştır. FAO-WRB referans sistemi 2. düzeyinde toprak sınıflarının tahmini için kullanılan modele ait değişkenlerin katsayıları Çizelge 4.16’da FAO-WRB referans sistemi 2. düzeyinde toprak sınıflarının doğruluk değerlendirmesi için hesaplanmış karışım matrisi Çizelge 4.17’de verilmiştir. FAO-WRB referans sistemi 2. düzeyinde toprakları sınıflandırmak amaçlı üretilen modelde önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.21’de ve önemli değişkenlere ait kutu grafikleri Şekil 4.20’de verilmiştir. FAO-WRB referans sistemi 2. düzeyinde toprakların en muhtemel sınıfa aitliklerini ve her bir FAO-WRB referans sistemi 2. düzeyinin oluşma olasılıklarının mekânsal haritaları Şekil 4.22’de verilmiştir.




Çizelge 4.16. FAO - WRB 2. düzey toprak sınıflarının tahmininde model değişken katsayıları


FAO-WRB	Kesişim Noktası	Akış Birikim	Akış Doğ.	Bakı	Hue indeks	Nor.Çıplak Toprak İnd.	Nor. Kireçli Sediment İnd.	Nor. Karbonat İnd.
ChromicCambisol	22.2633	-0.007314	-0.008120196	-0.018023028	0.01758996	10.4939667	-3.653804	-7.1422389
EutricCambisol	12.96912	-0.007084	0.012692055	0.00095476	8.10224262	0.3586164	-13.748676	-1.7811139
EutricVertisol	33.30131	-0.006801	0.012072014	-0.002058742	-4.63503475	2.5526448	-15.017232	-13.1133834
HaplicCalcisol	-23.79445	-0.011034	0.002014921	0.000953751	11.84353585	25.2760089	-67.126644	0.4858959
MollicFluvisol	57.6176	0.000055	0.017478906	0.00187737	3.54501671	23.9010201	-9.698825	15.4992267
PetricCalcisol	-37.31104	-0.001825	-0.003718127	0.000141795	0.31474114	1.4666944	7.396898	9.828267
VerticCambisol	115.59215	-0.035541	0.019415034	-0.003751326	2.46355063	41.9823315	-65.798812	33.8546818
FAO-WRB	Eğrilik	Eğim Uz.	Planform E.	Profil Eğriligi	Nor. Demir (FeO+2) İnd.	Nor. Demir İnd.	Nor. Kil İnd.	Parlaklık İndeksi
ChromicCambisol	0.3291813	-0.07586961	-0.09374967	-0.42293323	7.069784	-17.455739	-10.184433	4.399408
EutricCambisol	0.4159717	-0.16570932	-0.12429369	-0.54034344	-6.70109	-1.301958	-15.88195	11.758593
EutricVertisol	0.0689469	0.17185856	-0.92446971	-0.9933944	3.788568	-15.085762	-20.093744	13.09
HaplicCalcisol	0.2490727	-0.11497225	0.1678368	-0.08126511	28.190448	-24.221278	19.180021	-64.576876
MollicFluvisol	0.2531757	-0.04745915	-1.08172496	-1.33484936	-2.535518	-10.460502	-11.217817	4.779995
PetricCalcisol	0.2138424	0.14232165	-0.10103539	-0.31485988	7.170601	8.793263	13.600492	-14.015481
VerticCambisol	0.3123958	0.34838266	0.12477646	-0.18761312	2.184004	-8.584408	2.934096	-3.163513
FAO-WRB	Akış Gücü İn.	Topoğ. Isl.İnd.	Yükseklik	Eğim (%)	Nor. Bitki Fark İnd.	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İnd.	Üst Top.Tane Büy. İnd.
ChromicCambisol	5.79536281	-5.32612486	0.015663613	-1.80607351	0.5086255	18.598979	0.7629549	-6.659128
EutricCambisol	0.19531732	0.02294862	-0.012683844	-0.07427413	-3.400037	-22.054828	-5.1000996	-2.264249
EutricVertisol	0.18349949	-0.19665469	-0.037582172	-0.16619642	1.3644268	-1.832887	2.0466065	-11.90597
HaplicCalcisol	0.30089727	0.05559052	0.002532991	-0.15684407	10.7556382	48.1639	16.1334812	3.401415
MollicFluvisol	0.08532241	-0.11243994	-0.059944008	0.02128563	-1.4875092	-46.555461	-2.2312261	12.602366
PetricCalcisol	0.27790137	-0.53735307	0.04303426	-0.30913849	-0.3584181	-26.880091	-0.5376465	5.339628
VerticCambisol	0.3370088	-0.13449411	-0.141709022	-0.26952931	8.5018605	17.935061	12.7527957	22.926658

Çizelge 4.17. FAO - WRB 2. düzey toprak sınıflandırma sonuçlarının karışım matrisi


		GÖZLEM									
		Calcaric Fluvisol	Chromic Cambisol	Eutric Cambisol	Eutric Vertisol	Haplic Calcisol	Mollic Fluvisol	Petric Calcisol	Vertic Cambisol	Toplam	Kullanıcı
TAHMİN	Eğitim Seti										
	CalcaricFluvisol	24	1	1	1	5	3	4	1	40	%60
	Chromic Cambisol	1	5	1	0	1	1	0	0	9	%56
	EutricCambisol	8	1	53	11	4	10	1	1	89	%60
	EutricVertisol	2	0	1	10	3	4	0	1	21	%48
	HaplicCalcisol	10	4	8	6	27	4	6	2	67	%41
	MollicFluvisol	6	0	10	12	13	45	1	4	91	%50
	PetricCalcisol	2	0	1	0	4	1	7	0	15	%47
	VerticCambisol	0	0	1	0	3	4	0	12	20	%60
	Toplam	53	11	76	40	60	72	19	21	183	
	Üretici	%46	%46	%70	%25	%45	%63	%37	%58	Genel D.	%52
	Kappa										0.42=%42
	Test Seti	Calcaric Fluvisol	ChromicCambisol	Eutric Cambisol	Eutric Vertisol	Haplic Calcisol	Mollic Fluvisol	Petric Calcisol	Vertic Cambisol	Toplam	Kullanıcı
	CalcaricFluvisol	18	3	3	2	0	0	2	0	28	%65
	Chromic Cambisol	0	0	1	0	1	0	0	0	2	%0
	EutricCambisol	2	1	22	8	3	4	1	2	43	%52
	EutricVertisol	0	1	1	0	0	1	0	0	3	%0
	HaplicCalcisol	4	1	1	0	12	3	2	1	24	%50
	MollicFluvisol	1	0	9	7	5	14	0	2	38	%37
	PetricCalcisol	3	0	1	0	2	0	1	0	7	%15
	VerticCambisol	0	0	0	0	1	1	0	4	6	%67
	Toplam	28	6	38	17	24	23	6	9	71	
	Üretici	%65	%0	%58	%0	%50	%61	%17	%45	Genel D.	%48
										Kappa	0.35=%35



Şekil 4.20. FAO-WRB 2.düzyer sınıflandırma modelinde önemli değişkenlere ait kutu grafikleri



Şekil 4.21. FAO-WRB 2.düzyer düzeyi sınıflandırma modelinde değişkenlerin göreceli önemi



Şekil 4.22. FAO-WRB 2. seviyesi en olası sınıf ve sınıf olasılıklarının mekânsal haritaları

Çalışma alanında mevcut 8 adet FAO dünya referans sistemi 2. seviyesine ait toprakların sınıflandırılması sonucunda eğitim setinde genel doğruluk %52, test setinde genel doğruluk %48 olarak belirlenmiştir. Forghani vd. (2020), ikinci seviyede 18 WRB toprak grubu mevcut bulunan alanda yaptıkları sınıflandırma çalışmasında, çok terimli lojistik regresyon (MNLR) modeli sonucu haritalama neticesinde WRB'nin ikinci seviyesindeki genel doğruluğunu, %11 ve kappa katsayısını %0 olarak

belirlemişlerdir. Yine benzer koşulların hâkim olduğu yarı kurak bir alan olan Cezayir'de yapılan bir araştırmada, 22 573 hektarlık bir alanda eğitim için 361 örnek kullanarak WRB ikinci düzeyinde 13 sınıfla %64.4 genel doğruluk elde edilebilmiştir (Assami ve Hadi-Aisa 2019). Leneaars vd. (2020), Etiyopya'nın dağlık bölgesinde 26820 km² alanda rastgele orman modeli kullanarak yaptıkları haritalama çalışmasında toprak kaynakları için Dünya referans sistemi (WRB) seviyelerinde %58'lik bir doğruluk elde edildiğini bildirmektedirler. Dotto vd. (2020), sadece çevresel değişken olarak uzaktan algılama ürünü çevresel değişkenler kullanılarak WRB düzeyinde %83'lük genel doğruluk elde edilebileceğini bildirmektedir. Özellikle üst sınıflandırma seviyelerinde çevresel değişken olarak uydu görüntülerinden üretilen toprak ve bitki indislerinin kullanımının öne çıktığı görülmektedir. Şekil 4.21'deki modelde etkili değişkenlerin göreceli önem grafiği dikkate alındığında önemli değişkenlerin Amerikan toprak sınıflandırma sistemi ordo düzeyi ile çok benzer olduğu görülebilecektir. Bu kapsamda her iki farklı sınıflandırma sistemi olsa da aynı alanda benzer çevresel değişkenlerle tahmin edilebildikleri söylenebilir ve oluşumunda etkili olan faktörlerin dijital olarak doğru seçilen çevresel değişkenlerle doğru sınıflandırmalarının daha da yükselebileceği düşünülmektedir.

4.2. K Ortalama

Denetimsiz sınıflandırma, toprak sınıflandırmasında bir ön adım olarak toprak-arazi ilişkilerindeki örüntüleri tanımlamak için uzaktan algılanan spektral verilere ve topografik değişkenlere uygulanmıştır (Dobarco vd., 2021). Kümeleme, çevresel değişkenlerin veri setini, bir grup içindeki toprak oluşturan faktörlerin homojen ve farklı grupların öğelerinden farklı olduğu gruplara ayırmak için kullanılmıştır.

Metodolojik olarak yorumlanabilirlik katmak için kullanılan paket içerisindeki “unsupervised” fonksiyonunun 2 parametresinin dikkatli şekilde belirlenmesi gerekir. “nsamples”, k ortalama kümeleme algoritmasında rastgele bir piksel alt kümesine (nSamples) göre hesaplama yapılacağı zaman girilmesi gerekli bir parametredir. Kümeleme algoritması, görüntünün tüm pikselleri için çalıştırılabilir (clusterMap = FALSE), ancak bu durumun yavaş olabileceği ve bellek açısından güvenli olmadığı bildirilmektedir (Leutner vd., 2019). Nitekim 30 metrelik mekânsal çözünürlüğe sahip raster veri setimizde bu durum gürültüye sebep olabilir, yorumlama ve çıkarım yapma

becerimizi düşürebilir. Bu nedenle, genellikle uzaktan algılama görüntülerinde olduğu gibi büyük raster verileri olduğunda (işlenecek veri boyutu > bellek boyutu), (clusterMap = TRUE (varsayılan)) “nsamples” değeri belirlenir (Leutner vd., 2019). Bu değer mevcut temel haritanın ölçeği dikkate alınarak belirlenmeye çalışılmıştır. Mevcut karşılaştırma yapacağımız harita ölçeği 1:25000 ölçeğinde, haritanın 1 cm² sinin gerçek alanda karşıladığı büyüklük 62.5 ha’ya tekabül etmektedir. Yaklaşık 69 adet pikselin herhangi bir geometrik şekille bu alanı kaplayabileceği öngörülmekte ve bu öngörü doğrultusunda seçilecek piksel alt kümesinde 69 pikselin yer alması gerekliliği bildirilmiştir. “nsamples” tüm kategoriler için aynı değer olacak şekilde çalıştırılmıştır. Daha sonra tüm piksellerin küme merkezlerine olan mesafesi, tahmin kullanılarak aşamalı bir şekilde algoritma tarafından hesaplanmıştır. Sınıf ataması, küme merkezlerine olan minimum Öklid mesafesine dayanmaktadır. K ortalama algoritmasının çözümü genellikle rastgele seçilen sınıf merkezlerinin başlangıç konfigürasyonuna bağlıdır. Bu nedenle, k ortalama, farklı başlangıç konfigürasyonlarından yakınsak bir çözüm bulmak için genellikle çoklu rastgele başlatma konfigürasyonları ile çalıştırılır. “nStarts” parametresi, rastgele başlatmanın ne kadar yapılacağını belirtmeye olanak verir. Bu değer 10 olarak uygulanmıştır.

“nclass” değeri mevcut veri ile karşılaştırmalar yapabilmek için haritadaki sınıflandırma seviyeleri olarak belirlenmiştir. Sonuçlar itibari ile K değeri 4 aldığında ve K değeri 5 aldığında mevcut harita ile benzer sınıflar oluşabilmiş ve uzman bilgisi kontrolünde kümeleme ile oluşmuş sınıflara toprak sınıfları atanabilmektedir. K değerinin, 8, 10 ve 20 olması durumlarında karşılık gelen toprak sınıflandırma seviyelerine uzman bilgisince atama yapılamamış, sadece görsel değerlendirmeler de bulunulmuştur.

Açıklanan aşamalar doğrultusunda K değeri 4, 5, 8, 10 ve 20 olacak şekilde sınıflandırma algoritması çalıştırılmıştır. Sonuçlar girilen K değerlerine göre ayrı ayrı verilmiştir.

4.2.1. K değerinin 4 olması durumunda oluşan sayısal harita


K ortalama algoritması, k değeri 4 olacak şekilde çalıştırılmış ve Şekil 4.23’deki harita üretilmiştir. Kümelenen sınıflar uzman bilgisince mevcut harita lejandına göre ordo

sınıflarına atanmıştır. 83 adet nokta, oluşturulan tematik haritada ve mevcut haritadaki ordo sınıfları ile karşılaştırılmış, karışım matrisi Çizelge 4.18’de verilmiştir.

Çizelge 4.18. K ortalama algoritması ordo düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi

GÖZLEM						TAHMİN	
Entisol	Inceptisol	Mollisol	Vertisol	Toplam	Kullanıcı		
7	6	2	1	16	%79		
7	22	14	3	46	%66		
5	3	5	1	14	%61		
5	0	0	2	7	%50		
24	31	21	7	36	Genel D. %43		
%29	%71	%24	%28				

Karışım matrisi göz önüne alındığında genel doğruluk %43 olarak hesaplanmıştır. Özellikle denetimli sınıflandırma algoritması sonucu üretilen doğruluk değerine göre %30’luk bir düşüş mevcuttur. Entisol ve Inceptisol arasında karışım fazladır nitekim özellikle eğim ve yükseklikçe tanımlaması yapılamayan genç dere yatağı bölgesi entisol olarak tanımlanamayıp tamamen Inceptisol olarak tanımlanmıştır. K-ortalama yaklaşımının ordo düzeyinde Inceptisolü ve Entisolü olduğundan fazla hesapladığı görülebilmektedir. Bu durum Zeraatpisheh vd. (2019), Inceptisol ve Entisol ordolarının bulunduğu alanda k ortalama algoritmasınca fazla alanda sınıflandırıldığını bildirmiştir. Bu durum çalışma alanlarının alüvyal taşkın ova ve eski-yeni dere yataklarının ayırımında kümeleme algoritmasının kullanımının zorluğunu ortaya koymaktadır. Literatürde, elde edilen sınıfların, toprak-çevre ilişkileri açısından anlamlı olup olmadıklarını belirlemek için yorumlanması tavsiye edilmektedir (Brown vd., 2017). Nitekim çalışma alanımızda kümeleme algoritması sonucu oluşan Sınıf 1, mevcut harita ile karşılaştırıldığında Inceptisol ordosu ile çok benzerlik göstermektedir. Sınıf 2 Mollisol ordosu ile yüksek benzerlik gösterir. Sınıf 3 özellikle eğim ve yüksekliğin etkisiyle entisol ordosu ile benzerlik göstermektedir. Vertisol ordosu, denetimli sınıflandırma algoritması ile de net bir ayırmda bulunulamayan bir sınıftır.



Şekil 4.23. K ortalama algoritması ordo düzeyinde toprak sınıfları haritası

Çalıştırılan fonksiyon sonucu,

unsupervised (img = covs, nSamples = 69, nClasses = 4, nStarts = 10)

Within cluster sum of squares by cluster:

(between_SS / total_SS = 74.3 %)

Elde edilen değerlere göre, K değerinin 4 olarak belirlenmesi sonucu kümeleme ile toplam varyansın %74.3'ü açıklanabilmektedir.


4.2.2. K değerinin 5 olması durumunda oluşan sayısal harita

K ortalamalar algoritması k değeri 5 olacak şekilde çalıştırılmış ve Şekil 4.24'deki harita üretilmiştir. Kümelenen sınıflar uzman bilgisince mevcut harita lejantına göre büyük grup sınıflarına atanmıştır. 83 adet nokta, oluşturulan tematik haritada ve mevcut haritadaki büyük grup sınıfları ile karşılaştırılmış, karışım matrisi Çizelge 4.19'de verilmiştir.

Çizelge 4.19. K ortalama algoritması büyük grup düzeyinde toprak sınıflandırma sonuçlarının karışım matrisi

GÖZLEM							TAHMİN
Haplo xerert	Calci xerept	Haplo xerol	Haplo xerept	Xero fluent	Toplam	Kullanıcı	
0	5	1	2	0	8	0%	
0	4	8	3	7	22	18%	
0	4	7	1	0	12	58%	
0	7	11	4	0	22	18%	
1	11	5	2	0	19	0%	
1	31	32	12	7	15	Genel D. %18	
0%	13%	22%	33%	0%			Üretici

Karışım matrisi göz önüne alındığında genel doğruluk %18 olarak hesaplanmıştır. Haploxerert yine en düşük doğrulukla belirlenen sınıflardan biri olmuştur. Xerofluvent tamamen Calcixerept olarak tahmin edilmiştir. Bunun sebebi kümeleme algoritmasında, yükselti farklılığının kümelemeyi etkilemiş olmasından kaynaklandığı düşünülmüştür. Zeraatpisheh vd. (2019), K-ortalama ayrıştırma yaklaşımının, Xerofluvent ve Haploxerept büyük gruplarının bulunduğu alanda büyük grup seviyelerinin genel doğruluğunun %15 civarı olduğunu bildirmiştir.



Şekil 4.24. K ortalama algoritması büyük grup düzeyinde toprak sınıfları haritası

Çalıştırılan fonksiyon sonucu,

unsupClass (img = covs, nSamples = 69, nClasses = 5, nStarts = 10)


Within cluster sum of squares by cluster:

(between_SS / total_SS = 89.0 %)

Elde edilen değerlere göre, K değerinin 5 olarak belirlenmesi sonucu kümeleme ile toplam varyansın %89'u açıklanabilmektedir.

4.2.3. K değerinin 8 olması durumunda oluşan sayısal harita

K ortalamalar algoritması k değeri FAO dünya referans sınıflandırma sistemi 2. seviye toprak sınıflarının mevcut sayısı göz önünde bulundurularak 8 olacak şekilde çalıştırılmış ve Şekil 4.25'deki harita üretilmiştir.



Şekil 4.25. K ortalama algoritması 8 sınıflı sayısal haritası

8 sınıflı kümeleme algoritmasının yürütülmesi sonucu oluşan harita, yine yükseklik ve eğim değişkenlerinin baskın olması sebebi ile Calcaric Fluvisol, Petric Cambisol ve Haplic Calcisol büyük gruplarını tek bir sınıf olarak kümelemiştir. İlgili büyük grupların bulunduğu alanlarda arazi kullanım değişimlerinin mevcudiyeti yansıma karakteristiklerini etkilemesi sebebi ile kümelenebilir olmayan örüntü biçimleri oluşturmuş olabilir.

Çalıştırılan fonksiyon sonucu,

unsuperClass (img = covs, nSamples = 69, nClasses = 8, nStarts = 10)


Within cluster sum of squares by cluster:

(between_SS / total_SS = 97.8 %)

Elde edilen değerlere göre, K değerinin 8 olarak belirlenmesi sonucu kümeleme ile toplam varyansın %97.8'i açıklanabilmektedir.

4.2.4. K değerinin 10 olması durumunda oluşan sayısal harita

K ortalamalar algoritması değeri alt grup sınıflarının mevcut sayısı göz önünde bulundurularak 10 olacak şekilde çalıştırılmış ve Şekil 4.26'daki harita üretilmiştir.



Şekil 4.26. K ortalama algoritması 10 sınıflı sayısal haritası

10 sınıflı kümeleme algoritmasının yürütülmesi sonucu oluşan harita, yine yükseklik ve eğim değişkenleri ile birlikte bakı değişkeninin etkin olduğu görülebilmektedir. Bakı durumlarına göre küçük bakı kümeleri oluştuğu, bakı çevresel değişkeni ve 10

sınıflı kümeleme algoritması sonucu üretilen harita karşılaştırıldığında görülebilmektedir.

Çalıştırılan fonksiyon sonucu,

unsuperClass (img = covs, nSamples = 69, nClasses = 10, nStarts = 10)

Within cluster sum of squares by cluster:

(between_SS / total_SS =85.6 %)

Elde edilen değerlere göre, K değerinin 10 olarak belirlenmesi sonucu kümeleme ile toplam varyansın % 85.6'sı açıklanabilmektedir.

4.2.5. K değerinin 20 olması durumunda oluşan sayısal harita

K ortalamalar algoritması değeri seri sınıflarının mevcut sayısı göz önünde bulundurularak 20 olacak şekilde çalıştırılmış ve Şekil 4.27'deki harita üretilmiştir

Çalıştırılan fonksiyon sonucu,


unsuperClass (img = covs, nSamples = 69, nClasses = 20, nStarts = 10)

Within cluster sum of squares by cluster:

(between_SS / total_SS =96.0 %)

Elde edilen değerlere göre, K değerinin 20 olarak belirlenmesi sonucu kümeleme ile toplam varyansın %96'sı açıklanabilmektedir.

Kümeleme algoritması sonucu oluşan 20 sınıflı harita, birkaç seri sınırı ile tutarlılık gösterebilmektedir. Özellikle ovanın çanak yapısını tanımlar şekilde kümeler oluşmuş, bu durumun yine jeomorfolojik yapıyı tanımlaması sebebiyle topoğrafik değişkenlerin etkin olduğu söylenebilir.



Şekil 4.27. K ortalama algoritması 20 sınıflı sayısal haritası

Schmidt vd. (2010), mevcut toprak haritalama birimlerinin keskin sınır çizgileri ile bölünmemiş segmentasyonlar üretmek için k ortalamalar algoritmasını kullanmış ve üretilen 10 sınıfın alan bütünlüğüne göre homojen sınıflar olduğunu bildirmiştir. Bu çalışma alanında diğer toprak oluşum faktörleri olmasa bile topoğrafyanın göreceli homojenize olması oluşan 20 sınıflı kümeleme haritasının gürültülü görünmesine sebep olabilmektedir. Browning ve Duniway (2011), denetimsiz sınıflandırma algoritmalarının yalnızca yorumlanabilir bir toprak sınıfları haritası sağlamanın yanında, aynı zamanda tanımlanmış benzersiz sınıflar, araziye diğer enterpolasyon türleri (örneğin, kriging) için katmanlara ayırmak veya tabakalı örnekleme de dikkate alınacak bir veri kaynağı olarak kullanılabileceğini bildirmişlerdir. Nitekim buna

yönelik araştırmalar devam etmektedir. Dobarco vd. (2021), k ortalama algoritmasını kullanarak, geliştirdikleri metodoloji sonucunda, belirli bir referans seviyesi için toprak oluşturan faktörleri temsil eden bölgeselleştirilmiş nicel durum değişkenleri kümesinden oluşturulan kavramsal bir toprak taksonu olarak “Pedogenon” kavramını önermişlerdir. Esnek modelleme çerçevesinde, yüksek çözünürlükte (90 m) geniş alanlar üzerinde pedogenon haritalarının oluşturulmasının toprak değişiminin nicel değerlendirmesinde ve toprak izleme araştırmalarının tasarlanmasında kullanılabileceğini bildirmektedirler.

Kümeleme analizinin sayısal toprak haritalamada nihai hedefi, ölçeği düşük eski haritaların ayrıştırılması süresince, elde edilen çevresel değişken değerlerinin küme ortalamalarının, bir toprak tipini tanımlayabileceği veya ayırma kolaylık sağlayabileceği bir nitelik yakalamaktır. Nitekim çalışılan alanlarda belirli topoğrafik ıslaklık değeri, bakı vb. çevresel değişken değerlerinin bir toprak sınıfını tanımlayabilecek şekilde kümelenmesi neticesinde bilgi çıkarımının kolaylaştırılması yoluyla metodolojiler geliştirilmektedir.

Bu kapsamda sonuçlarımız göz önüne alındığında, tematik görselleştirmenin yanı sıra kümelerin merkez noktaları ve kümelerin ortalama çevresel değişken değerleri göz önünde bulundurularak, sayısal toprak haritalarının üretiminde toprakların çevreleriyle ilişkilerini tanımlamak açısından fonksiyonel bilgiler verebileceği ifade edilebilir.

Kümeleme algoritmasının çalıştırılması sonucu varyans açıklama yüzdeleri dikkate alındığında K, 4 değeri aldığıda %74.3'lük bir değer elde edilmiştir. Burada açıklanamayan varyansın ordo düzeyindeki farklılıklarla ilişkili olabileceği yorumu yapılabilir. K, 20 değeri aldığıda varyans açıklama yüzdesi %96 olarak belirlenmiştir. Çevresel değişken setinin oluşturduğu mekânsal varyasyon %96 oranında 20 küme oluşturularak tanımlanabilmektedir. Kümelerin anlamlılığı ve arazide toprak etüt ve haritalama çerçevesinde değerlendirilmesi konularında çalışmalar artarak devam etmektedir.

Sayısal toprak haritalamada kümeleme yaklaşımları, eşsiz toprakların, benzersiz toprak oluşturan faktör kümelerinin ürünü olduğu kavramsal modeline dayanmaktadır.

Çalışma amacı yöntem karşılaştırmasına dayanmakla birlikte, yöntemlerin bilgi keşfedebilme yeteneğini ortaya koyma hedefi de mevcuttur. Bu kapsamda, çevresel değişkenlerin oluşturdukları kümeler arazi çalışması öncesi eşsiz bilgiler ortaya koyabilir. Geniş alanlar üzerinde ince çözünürlükte kümelenmiş sınıfları oluşturma işlemleri sayısal toprak haritalamanın yeniden üretilebilir ve farklı ölçeklerde kolayca uygulanabilme özellikleri eşlik ettiğinde, ayrıntılı toprak etütlerinin olmadığı geniş alanlar için ön bilgi çıkarımında yararlı olabilir (Regmi ve Rasmussen, 2018).

4.3. Denetimli ve Denetimsiz Sınıflandırma Algoritmalarının Karşılaştırılması

Bu kapsamda genel doğruluk değerleri göz önünde bulundurularak ordo ve büyük grup düzeylerinde denetimli ve denetimsiz algoritmaların karşılaştırması yapılmıştır.

Çizelge 4.2 dikkate alındığında, denetimli sınıflandırma sonucu ordo düzeyinde genel doğruluk eğitim setinde %65, test setinde ise %59 olarak belirlenmiştir. Denetimsiz sınıflandırma sonucunda ise ordo düzeyinde %43'lük bir genel doğruluk elde edilebilmiştir (Çizelge 4.18). Eğitim ve test verisi ortak düşünüldüğünde denetimsiz sınıflandırmada, denetimli sınıflandırmaya göre %25 daha az doğrulukla sınıflandırmalar yapılabilmektedir.

Çizelge 4.6 dikkate alındığında büyük grup düzeyinde toprak sınıflarının eğitim setinde %56, test setinde %51 doğrulukla belirlenebildiği görülmektedir. Denetimsiz sınıflandırma sonucunda büyük grup toprak sınıflarının %18 doğrulukla belirlenebildiği görülmektedir (Çizelge 4.19). Eğitim ve test verisi ortak düşünüldüğünde denetimsiz sınıflandırmada, denetimli sınıflandırmaya göre %60 daha az doğrulukla sınıflandırmalar yapılabilmektedir.

Denetimli sınıflandırma algoritmalarında etkin olan spektral değişkenlerin nispeten denetimsiz sınıflandırma yöntemlerinde etkin olmadığı söylenebilir. Metodolojik farklılığın etkisi net olarak görülüyor olabilir. Nitekim k ortalama algoritması, kümelerini tanımlamak için minimum kareler toplamını baz alarak ve Öklid mesafesini kullanarak bir yaklaşım sunarken, çok terimli lojistik regresyon maksimum olabilirlik ilkesine göre sınıflandırma yapmaktadır.

4.4. Bilgi Temelli Sınıflandırma

Bilgi temelli sınıflandırmada, bahsedilen tüm sınıflandırma yöntemlerinden farklı olarak toprak-arazi ilişkileri hakkında en öncelikli bilgiyi gerektirir. Çok sayıda saha çalışması ve dokümantasyonun yapıldığı ve toprak-arazi ilişkilerinin iyi belgelendiği ve anlaşıldığı alanlarda başarılı olabilir. Ayrıca, bilgi tabanında tanımlanmış olan belirli kuralları desteklemek ve ayırt etmek için yeterli tahmin edici veriler de gereklidir.


Bilgi temelli sınıflandırma çok zaman alan bir yaklaşımdır. Her bir sınıf için özel kurallar geliştirmek ve kuralları yinelemeli bir şekilde geliştirmek için toprak-arazi ilişkilerini yeterince iyi anlamak amacıyla alan gözlemleri yapılmasını gerektirmektedir. Kaynaklar mevcutsa, bilgiye dayalı sınıflandırma, özellikle bir toprak bilimcisinin bilgisini dijital veriler olarak aktarma kabiliyeti bakımından önemli olabilir.

Çok terimli lojistik regresyondan elde edilen değerli bilgiler ve toprak bilimcisinin arazi hakkındaki eğim ve yükseklik bilgileri birleştirilerek Ordo düzeyinde kural tabanlı sınıflandırmalar oluşturulabilmiştir. Diğer kategorilerde büyük veri yapılarını çözmek ve anlamlı kalıplar var ise keşfetmek amacıyla kullandığımız denetimli öğrenme algoritmalarına benzer sınıf ayrımları yapılamayacağı söylenebilir. Bu tez çalışmasında ordo sınıfında çalışma alanı toprakları için ArcGIS “raster calculator” aracında üretilen koşul ifadeleri Çizelge 4.20’de verilmiştir.

Çizelge 4.20. Ordo sınıfları için kural ifadeleri

Ordo	Kural dizisi
Entisol	Con (((“Normalize Kireçli Sediment İndeksi”>=-0.2371409218528) & (“Eğim (%)”>7)), 1) 1= Entisol
İnceptisol	Con (((“Normalize Kireçli Sediment İndeksi”>=-0.240) & (“Parlaklık İndeksi”<0.167) & (“Eğim (%)”<5)), 2) 2 =İnceptisol
Mollisol	Con (((“Normalize Demir (FeO+2) İndeksi”>= 0.10) & (“Normalize Çıplak Toprak İndeksi”>= 0.08) & (“Eğim (%)”<= 3) & (“Yükseklik”<= 975)), 3) 3 =Mollisol
Vertisol	Con (((“Normalize Kil İndeksi”>= 0.13) & (“Normalize Kireçli Sediment İndeksi”<-0.21) & (“Eğim (%)”<= 2) & (“Yükseklik”<1000) & (“Yükseklik”> 955) & (“Normalize Çıplak Toprak İndeksi”<= 0.01)), 4) 4 =Vertisol

Bu kapsamda ordo sınıfına dair bilgi temelli oluşturulan harita Şekil 4.28 'de sunulmuştur.



Şekil 4.28. Kural ifadeleri sonucu oluşturulan ordo haritası

Şekil 4.28’de kural ifadeleri sonucu oluşturulan harita göz önüne alındığında diğer tüm sınıflandırma yöntemlerinde olduğu gibi vertisol ordosunun belirlenebilirliği çok zor olmaktadır.


4.5. Toprak Özellikleri ile Çevresel Değişkenler Arasındaki İlişkiler

Toprak örneklerinde belirtilen analiz sonuçları Ek Çizelge A.1’de verilmiştir. Laboratuvar analizlerine ait görseller Ek Şekil B.1’de verilmiştir Toprak özellikleri ile çevresel değişkenler arasındaki ilişkileri araştırmak amacıyla mevcut topoğrafik değişkenlere ek olarak toprak örneklemelerinin yapıldığı tarihe en yakın tarihteki Sentinel 2A-MSI uydusu temin edilmiş ve Çizelge 3.4’teki indeksler üretilmiştir. Sentinel 2A-MSI uydusundan elde edilen çevresel değişkenlerin haritaları Şekil 4.29’da verilmiştir.

4.5.1. Tanımlayıcı istatistikler

Analizler sonucu elde edilen veri setinde tanımlayıcı istatistikleri belirlenmiş ve sonuçları Çizelge 4.21’de verilmiştir. Aynı çizelge içerisinde çevresel değişkenlerin tanımlayıcı istatistik parametreleri de bulunmaktadır.

Toprak özellikleri için değişkenliğin derecesini varyasyon katsayısı göz önünde bulundurularak değerlendirilmek istenirse, %0-15 düşük varyasyon, %16-35 orta ve %36’dan fazla varyasyon katsayısı değerleri (CV) yüksek değişkenliği gösterdiği bildirilmektedir (Oku vd., 2010) Toprak özellikleri içerisinde alüvyal bir ovada kil ve kum yüksek değişkenliğe sahiptir. Yoğun olarak tarım yapılan bir ova olan çalışma alanında toprak kimyasal özelliklerinden olan pH’ın varyasyon katsayısı çok düşük iken, EC değeri, % organik madde ve değişebilir Na değerleri yüksek varyasyon katsayısına sahiptir. Bu durum arazi kullanımının ve tarımsal uygulamaların toprak kimyasal özelliklerini etkileyebildiği ancak pH için bu durumun çok geçerli olmadığı söylenebilir. % kalsiyum karbonat eşdeğerinin özellikle çalışma alanın güney bölgelerinde eski birikinti bölgelerini oluşturan alanlarda kalsiyumun yüzeyden yıkanmasının ve genç birikintilerde fazla kalsiyumlu minerallerin varlığı ile çok değişkenlik gösterebileceği söylenebilir. Topoğrafik çevresel değişkenler göz önüne alındığında yükseklik hariç tüm değişkenler yüksek varyasyona sahiptir. Rakımsal olarak bölünmemiş taşkın yatağındaki alanlarda bu durum beklenen bir durumdur ve yükseklik açısından çalışma alanı çok az değişkenlik göstermektedir (Başayığıt ve Şenol, 2008).




Şekil 4.29. Sentinel 2A-MSI uydu görüntüsünden üretilen çevresel değişkenler

Çizelge 4.21. Toprak analiz sonuçları ve çevresel değişkenlerin tanımlayıcı istatistikleri

	n	Ort.	Standart S.	Min.	Mak.	Çarpıklık.	Basıklık	Varyasyon kat. (%)
Hue indeksi	91	0	0	0	0.01	0.42	0.94	16.7
Normalize Kireçli Sediment İndeksi	91	0.48	0.05	0.34	0.6	-0.38	-0.05	10.91
Normalize Çıplak Toprak İn.	91	0.34	0.06	0.17	0.48	-0.28	0.43	16.34
Normalize Karbonat İnd.	91	0.19	0.04	0.11	0.31	0.44	-0.47	22.9
Normalize Demir (FeO+2) İndeksi	91	0.09	0.06	-0.08	0.2	-1.06	0.4	70.06
Normalize Demir İndeksi	91	-0.17	0.05	-0.32	0.04	0.27	2.03	-31.78
Normalize Kil İndeksi	91	0.17	0.03	0.11	0.25	0.52	-0.04	17.13
Normalize Bitki Fark İndeksi	91	0.2	0.07	0.1	0.48	1.94	4.15	36.08
Parlaklık İndeksi	91	16.51	2.42	11.7	22.66	0.1	-0.88	14.65
Satursayon İndeksi	91	1.18	0.29	0.63	1.96	0.35	-0.58	24.4
NormalizeTop. Ayarlı Bitki İn.	91	0.29	0.11	0.15	0.73	1.94	4.15	36.08
Üst Toprak Tane Büyüklük İndeksi	91	0.16	0.04	0.09	0.26	0.5	-0.54	25.81
Planform Eğriliği	91	-0.02	0.46	-1.28	1.28	0.15	0.74	-2166.57
Profil Eğriliği	91	0.01	0.49	-1.15	0.96	-0.14	-0.99	3494.28
Eğrilik	91	-0.04	0.86	-1.92	1.92	0.26	-0.48	-2447.25
Akış Gücü İndeksi	91	0.89	1.88	-4.38	6.53	0.58	0.95	210.16
Topografik Islaklık İndeksi	91	6.92	1.72	4.65	12.75	1.03	0.46	24.79
Eğim Uzunluğu	91	1.54	2.56	0	14.59	2.86	9.12	165.91
Bakı	91	182.63	95.23	-1	348.69	-0.37	-0.63	52.14
Akış Doğrultusu	91	24.8	37.78	1	223	2.56	8.01	152.33
Eğim (%)	91	6.48	4.13	0	18.94	0.77	0.22	63.63
Akış Birikim	91	28.2	134.87	0	1229	7.89	66.31	478.29
Yükseklik	91	1015.37	40.89	955	1122	0.38	-0.81	4.03
Kil (%)	91	36.91	13.68	13.28	73.76	0.82	-0.22	37.06
Silt (%)	91	25.81	7.16	12.47	51.94	1.13	1.64	27.72
Kum (%)	91	37.29	15.01	6.35	69.3	-0.34	-0.87	40.26
pH	91	7.68	0.34	6.34	8.07	-1.77	2.92	4.49
EC (mS cm ⁻¹)	91	0.61	0.29	0.11	2.07	2.01	7.21	47.13
Org.Mad. (%)	91	2.37	1.06	0.76	6.11	1.52	2.95	44.69
CaCO ₃ Eşdeğeri (%)	91	9.81	8.83	0.26	35.08	0.99	0.36	90.01
KDK (cmol kg ⁻¹)	91	22.75	6.75	9.34	40.24	0.71	0.05	29.67
Değişebilir Na (cmol kg ⁻¹)	91	0.18	0.2	0.08	1.76	6.21	44.36	112.16
Değişebilir Na (%)	91	0.8	0.9	0.31	8.3	6.76	51.41	112.91

Topoğrafik ıslaklık indeksi ile toprak özelliklerinin herhangi biri arasında önemli düzeyde ilişki bulunmamıştır. Toprak özellikleri en yüksek ilişkiler yükseklik ve % eğim değerleri ile mevcuttur.


Toprak örnekleri ile topoğrafik çevresel değişkenler analizinde yürütülen korelasyon analiz sonuçları Şekil 4.30'da verilmiştir. Korelasyon analizi sonuçlarına göre $P < 0.05$ düzeyinde önem dikkate alınarak görselleştirmeler yapılmıştır. X işareti $P > 0.05$ durumunu ifade etmektedir.



Şekil 4.30. Toprak özellikleri ile topoğrafik çevresel değişkenler arasındaki korelasyon grafiği

Şekil 4.30'daki toprak özellikleri ile çevresel değişkenler arasındaki korelasyon değerleri göz önüne alındığında, KDK ile % kum içeriği arasında negatif yönde 0.70 civarı korelasyon ($P < 0.05$) mevcuttur. Yine KDK ile % Kil içeriği arasında pozitif yönde 0.80 civarı korelasyon ($P < 0.05$) mevcuttur. % Silt ile CaCO_3 eşdeğeri (%) arasında $r:0.68$ korelasyon ($P < 0.05$) mevcuttur. Kowalska vd. (2019), Kireç içeriği yüksek ana materyalin olduğu bölgede yaptıkları çalışmada, kalsiyum karbonat bakımından zengin topraklarda çeşitli boyut aralıkları tanımlanmasında; silt içeriğinin yüksek olduğu bildirilmiştir. Çalışma alanının Org. Mad. (%) ile KDK (cmol kg^{-1}) arasında önemli bir ilişki bulunmamıştır. Bunun nedeni olarak tarımsal üretimin yoğun olduğu çalışma alanında tarımsal uygulamaların toprak pedojenik işlemlerinden daha etkili olduğu söylenebilir. Topoğrafik değişkenlerden eğimin kil ve silt ile negatif yönde zayıf, kum ile pozitif yönde ilişkiler göstermesi çalışma alanı gerçeğiyle uyumludur.

Toprak özellikleri ile spektral çevresel değişkenler arasındaki korelasyon ilişkileri Şekil 4.31’de verilmiştir.



Şekil 4.31. Toprak özellikleri ile spektral çevresel değişkenler arasındaki korelasyon grafiği

Toprak özellikleri ile spektral çevresel değişkenler arasındaki ilişkiler Şekil 4.31 değerlendirildiğinde uydu görüntüsünü alınma zamanının ekim dönemi ve bitkisiz dönem görüntüsü olmasına rağmen, bitki indeksleri olarak tanımlanan indekslerin organik madde ile pozitif yönde ilişkili olduğu belirlenmiştir. Yang vd. (2015), belirli bir periyot süresince elde edilen bitki indislerinin (NDVI) toprak organik karbonu ile ilişkilerinin o periyot boyunca pozitif yönde olduğunu bildirmiştir.

Çevresel değişkenlerle toprak özellikleri arasında düşük korelasyon olduğu açıktır. Bu durumda toprak biliminde yorumlanabilirlik üzerine toprak özelliklerini çevresel değişkenlerle tahminine yönelik çalışmalar yürütülmektedir. Bu kapsamda, toprak örneklerinde belirlenen kil (%), kum (%), organik madde (%), katyon değişim kapasitesi değerleri ile çevresel değişkenler arasındaki ilişkiler belirleyebilmek ve

bunlar arasında var ise ilişkilerini açığa çıkarabilmek ve keşfin derinleştirilmesi amacıyla çoklu regresyon yöntemleri kullanılarak istatistiksel analizler yürütülmüştür.

4.5.2. Çoklu doğrusal regresyon ile belirli toprak özelliklerinin tahmini


Veri setinde yapılan modelleme sonucunda istatistiki olarak önemli bulunan, kil, kum, organik madde, katyon değişim kapasitesinin çoklu doğrusal regresyonda bağımlı değişkenler olduğu modellerdir. Bağımlı değişkenlerin histogram grafikleri istatistiki analizler öncesi incelenmiş ve Çizelge 4.21 göz önünde bulundurularak bağımlı değişkenlerde herhangi veri bir dönüşüm işlemi yapılmamıştır. R programında (R Core Team, 2020) yürütülen çalışmalar sonucunda modeldeki değişkenlerin öneminin belirlenerek yorumlamada kolaylık sağlanmıştır.

4.5.2.1. Toprak kil içeriğinin çevresel değişkenlerle tahmini

Toprak kil içeriğine yönelik tahmin de kullanılan model katsayıları ve model performans değerleri Çizelge 4.22’de verilmiştir. Belirleme katsayısı (R^2) 0.58, Kök ortalama kare hatası (RMSE), %8.79 olarak belirlenmiştir. Model sonucunda önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.32’de verilmiştir.

Çizelge 4.22. Kil içeriği tahmininde model değişken katsayıları

	R2:0.58:	Hue ind.	Nor. Kir. Sediment İnd.	Nor. Çıp.Topr. İnd.
Kil	RMSE: %8.79	19610.00	-363.70	290.10
	Nor.Kar. İnd.	Nor.Demir (FeO+2) İnd.	Norm. Demir İnd.	Norm. Kil İnd.
	-1814.00	27.87	55.70	484.10
	Norm. Bitki Fark İnd.	Parlaklık İndeksi	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İndeksi
	1225000.00	-15.26	83.33	-1225000.00
	Üst Toprak Tane Büyüklük İnd.	Planform Eğriliği	Profil Eğriliği	Akış Gücü İndeksi
	1545.00	4.65	1.85	1.46
	Topoğrafik Islaklık İndeksi	Eğim Uzunluğu	Bakı	Akış Doğrultusu
	-1.13	0.05	-0.02	0.00
	Eğim (%)	Akış Birikim	Yükseklik	Kesişim Noktası
	-0.77	-0.01	-0.11	497100.00



Şekil 4.32. Kil tahmininde modelde kullanılan değişkenlerin göreceli önemi

Şekil 4.32 göz önünde alındığında toprak kil içeriğinin tahmininde modelde en önemli değişken yükseklik olarak belirlenmiştir. Yükselti farkları ile bölünmeyen ovada eski birikinti bölgeleri ile yeni birikim bölgeleri arasında yaklaşık 150 metre rakım farklılığı mevcuttur. Bu durum toprak kil içeriğinin bu iki farklı bölgede farklılaşmasına neden olmuştur. Mosleh vd. (2016), İran’da nispeten düz bir tarım ovasında yaptıkları çalışmada, spektral ve topoğrafik değişkenler kil içeriği tahmininde R^2 değerinin 0.24, ve RMSE değerini %8.7 olarak belirlemişlerdir. Yüksekliğin modele en önemli ikinci katkı sağlayan değişken olduğunu bildirmişlerdir. En önemli çevresel değişkenler olarak spektral çevresel değişkenler belirlenmiştir. Poppiel vd. (2021), geniş ölçekte üst toprak kil içeriğinin tahminini yapmak amacıyla yürüttükleri çalışma sonucunda, kil için eğitim setinde R^2 :0.73, RMSE değerini %7, test setinde R^2 :0.62 RMSE %8.54 olarak belirlemişlerdir. Ölçek fark etmeksizin yakın R^2 ve RMSE değerleri elde edilmiştir. Kil tahmininde önemli çevresel değişken olarak, iklim değişkenlerinden sonra en önemli değişkenlerin spektral değişkenler olduğu belirlenmiştir. Bununla birlikte karşılaştırılan çalışmada,


iklim verilerinin çevresel değişken olarak kullanılması doğruluğu artırmış olabilir. Fongaro vd. (2018), Brezilya ölçeğinde uydu görüntülerinden üretilen çevresel değişkenleri kullanarak yaptıkları çalışmada kil içeriğini R^2 : 0.83, RMSE değerini %6.5 olarak belirlemişlerdir. Multispektral uydu görüntülerinden üretilen çevresel değişkenlerin, toprak özelliklerinin tanımlanmasında topoğrafik parametrelerden daha kararlı olduğunu bildirmişlerdir. Loiseau vd. (2019), toprak kili içeriğinin (0-30 cm) uzaktan algılama verilerini ile tahminine yönelik Fransa kapsamında yürüttükleri çalışmada, yüzey örneklerinde kil içeriğinin tahmininde R^2 değerlerinin 0.45'den yüksek, RMSE değerlerinin %9'dan düşük olarak belirlemişlerdir. Adhikari vd. (2013), kil için R^2 0.50'den 0.55'e; Poggio vd. (2013), R^2 0.27 ve 0.49; Rossel vd. (2015), R^2 0.39'dan 0.52'ye değişen aralıklarda sonuçlar bulmuşlardır. Bu tez çalışmasında elde edilen değerler, ölçek ve kullanılan çevresel değişken benzerliği de göz önüne alınıp literatürdekilerle karşılaştırıldığında kabul edilebilir ($R^2 > 0.45$) görünmektedir.

4.5.2.2. Toprak organik madde içeriğinin çevresel değişkenlerle tahmini

Toprak organik madde (%) içeriğine yönelik tahmin de kullanılan model katsayıları ve model performans değerleri Çizelge 4.23'de verilmiştir. Belirleme katsayısı (R^2) 0.40, Kök ortalama kare hatası (RMSE), %0.81 olarak belirlenmiştir. Model sonucunda önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.33'te verilmiştir.

Çizelge 4.23. Organik Madde içeriği tahmininde model değişken katsayıları

	R²:0.40:	Hue ind.	Nor. Kir. Sediment İnd.	Nor. Çıp.Topr. İnd.
Organik Madde	RMSE: % 0.81	168.90	-43.10	33.55
	Nor.Kar. İnd.	Nor.Demir (FeO+2) İnd.	Norm. Demir İnd.	Norm. Kil İnd.
	16.09	-0.22	-3.35	36.60
	Norm. Bitki Fark İnd.	Parlaklık İndeksi	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İndeksi
	-121600.00	0.16	0.41	81090.00
	Üst Toprak Tane Büyüklük İnd.	Planform Eğriliği	Profil Eğriliği	Akış Gücü İndeksi
	-27.42	0.40	-0.01	-0.0823
	Topoğrafik Islaklık İndeksi	Eğim Uzunluğu	Bakı	Akış Doğrultusu
	-0.04	0.0606	-0.0008	0.0027
	Eğim (%)	Akış Birikim	Yükseklik	Kesişim Noktası
	0.013	0.0011	0.000238	6.71



Şekil 4.33. Organik madde tahmininde modelde kullanılan değişkenlerin göreceli önemi

Şekil 4.33 göz önünde alındığında toprak organik madde içeriğinin tahmininde modelde en önemli değişkenlerin topoğrafik faktörler olduğu görülmektedir. Poppiel vd. (2021), Ortadoğu bölgesinin organik karbon haritasını oluşturdukları çalışmada eğitim seti için R^2 0.81, RMSE %0.30, test seti için R^2 :0.48 RMSE %0.35 olarak belirlemişlerdir. Organik karbon tahmininde yıllık toplam yağış değişkeninden sonra en önemli değişkenlerin, Sentetik Toprak Görüntüsü (SYSI) ve yükseklik olduğunu belirlemişlerdir. Forkuor vd. (2017), iklim, topoğrafik ve spektral değişkenlerle toprak organik karbonunu tahmin etmek amacıyla yaptıkları çalışmada, eğitim seti için R^2 :0.35, RMSE %0.55, test seti için RMSE %0.54 olarak belirlemişler, toprak organik karbonu tahmininde en önemli çevresel değişkenlerin yağış ve yükseklik değişkenlerinin olduğunu bildirmişlerdir. Sönmez vd. (2017), Türkiye'nin ulusal mekânsal toprak organik karbon bilgi sisteminin oluşturulması kapsamında iklim (sıcaklık, yağış, buharlaşma), topografya (eğim, bakı, yükseklik vb.), toprak tekstürü, ana materyal, jeoloji, bitki örtüsü (NDVI'nın minimum, maksimum ve ortalama verileri) ve arazi kullanım türü bilgilerinin, toprak organik karbon içeriğini tahmin

etmek için çevresel değişkenler olarak kullandıkları çalışmada R^2 : 0.32 RMSE %0.42 olarak belirlemişlerdir. Mosleh vd. (2016), hâkim düz ovada toprak organik karbonunu tahmini amacıyla yürüttükleri çalışmada, organik karbon içeriğinin tahmininde güneş radyasyonu, yükseklik ve karbonat indeksinin etkin değişkenler olduğunu bildirmişler, R^2 :0.26, RMSE %0.26 olarak belirlemişlerdir. Topoğrafyanın organik madde dağılımını etkilemesi ilgili olarak, güneş radyasyonu eğimin bir fonksiyonudur ve sıcaklığı kontrol ederek bitki örtüsünü etkileyebilmekte ve bu durumda organik karbon dağılımını değiştirebilmektedir (Marques ve Mora 1992). Alan Nath (2006), eğriliğin çoklu regresyon modeli ile organik karbonun tahmininde en önemli faktör olduğunu ve değişkenliğin %31'ini açıkladığını bildirmişlerdir. Bou Kheir vd. (2010), Danimarka'daki organik karbonu tahmini için yükseklik, toprak türleri ve eğimin etkili olduğunu bildirmiştir. Wiesmeier vd. (2011), organik karbon dağılımını kontrol eden en önemli değişkenlerin arazi kullanımı, toprak türleri ve jeoloji olduğunu belirtmişlerdir.


4.5.2.3. Katyon değişim kapasitesi içeriğinin çevresel değişkenlerle tahmini

Toprak katyon değişim kapasitesi içeriğine yönelik tahminde kullanılan model katsayıları ve model performans değerleri Çizelge 4.24'de verilmiştir. Belirleme katsayısı (R^2) 0.56, Kök ortalama kare hatası (RMSE), 4.45 cmol kg⁻¹ olarak belirlenmiştir. Model sonucunda önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.34'de verilmiştir.

Şekil 4.34 göz önünde alındığında katyon değişim kapasitesi içeriğinin tahmininde modelde en önemli değişken topoğrafik değişkenlerden olan yükseklik olmuştur. Yükseklikten sonra etkin değişkenler spektral verilerden üretilen çevresel değişkenler olmuştur. McKenzie ve Austin (1993), toprak özellikleri, katyon değişim kapasitesi ve topoğrafik değişkenler (eğim gradyanı, rölyef ve eğim konumu) arasındaki ilişkileri modellemek için doğrusal regresyon kullanmış ve modelleme aracılığı ile katyon değişim kapasitesinin varyasyonunun %64'ünün açıklanabildiğini ifade etmişlerdir.

Çizelge 4.24. Katyon Değişim kapasitesi tahmininde model değişken katsayıları

	R2:0.56:	Hue ind.	Nor. Kir. Sediment İnd.	Nor. Çıp.Topr. İnd.
Katyon Değişim Kapasitesi	RMSE: 4.45 cmol kg⁻¹	6885.00	-675.10	572.60
	Nor.Kar. İnd.	Nor.Demir (FeO+2) İnd.	Norm. Demir İnd.	Norm. Kil İnd.
	-343.00	-3.60	38.68	594.90
	Norm. Bitki Fark İnd.	Parlaklık İndeksi	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İndeksi
	345500.00	-6.27	23.62	-345500.00
	Üst Toprak Tane Büyüklük İnd.	Planform Eğriliği	Profil Eğriliği	Akış Gücü İndeksi
	159.00	3.00	2.07	-0.0019
	Topoğrafik Islaklık İndeksi	Eğim Uzunluğu	Bakı	Akış Doğrultusu
	-0.08	0.09	-0.01	0.00
	Eğim (%)	Akış Birikim	Yükseklik	Kesişim Noktası
	0.07	-0.0032	-0.04	140300.00



Şekil 4.34. Katyon değişim kapasitesi tahmininde modelde kullanılan değişkenlerin göreceli önemi

Chagas vd. (2018), tahmin modelleri ve uzaktan algılama verilerinden elde edilen çevresel değişkenler ile yarı kurak bir bölgede toprak katyon değişim kapasitesini

tahmin ettikleri çalışmada, R^2 değerlerinin 0.47 ile 0.57 arasında ve RMSE 7.22 cmol kg^{-1} ile 7.89 cmol kg^{-1} arasında belirlendiğini bildirmiştir. Önemli değişkenler arasında kısa dalga kızıl ötesi bantlarının olduğunu belirlemişlerdir. Normalize kil indeksi kısa dalga kızılötesi bantların aritmetik işlemi sonucu elde edilen bir indistir. Vaysse ve Lagacherie (2015), eski toprak verileri ve SYM'den türetilen topoğrafik veriler, Landsat 7 görüntüleri ve jeoloji haritalarının çevresel tahmin değişkeni kullanılması yoluyla katyon değişim kapasitesini tahmin etmek için rastgele orman modellerini uygulayarak tatmin edici sonuçlar elde edememiştir. Zayıf performansın, ana materyalin kısa mesafedeki büyük varyasyonuna ve katena sistemi boyunca erozyon/birikme oranlarının, girdi verileri olarak kullanılan ortak değişkenlerin mekânsal çözünürlüğü (100m) tarafından iyi bir şekilde yakalanamadığını bildirmişlerdir. Bu çalışmada çevresel değişken seti 30 metre mekânsal çözünürlükle üretilmiştir. Mevcut topografyayla ilgili arazi değişkenleri düşük tahmin gücüne sahip olduğundan, düz alanlarda zemin özelliklerinin mekansal varyasyonunu haritalamak bir zorluk olmaya devam etse de uzaktan algılama verileri, dijital haritalama teknikleri kullanılarak tahmin edilen toprak özellikleriyle daha iyi ilişkilendirilebilecek yüzey değişkenliğini temsil etmek için yararlı olabilecektir. Lagacherie vd. (2013), Topoğrafik değişkenler ve hiperspektral görüntüleri kullanarak yüzey topraklarında katyon değişim kapasitesini tahmin amacıyla yürüttükleri çalışmada, R^2 değerleri 0.71 ile 0.79 arasında RMSE 3.3 ile 4.6 cmol kg^{-1} arasında belirlemişlerdir. Hengl vd. (2015), Afrika ölçeğinde toprak özelliklerinin haritalanması amacıyla yürüttükleri çalışmada katyon değişim kapasitesi için RMSE: 11.0 cmol kg^{-1} değeri elde etmişlerdir. Safanelli vd. (2020), Avrupa ölçeğinde yaptıkları çalışmada katyon değişim kapasitesinin belirlenebilirliğine ve haritalanmasına yönelik yaptıkları çalışmada eğitim seti için R^2 :0.70, RMSE 4.38 cmol kg^{-1} , test seti için R^2 : 0.38 RMSE 7.66 cmol kg^{-1} olarak belirlemişlerdir. Sentinel 2A MSI uydusunda Kısa dalga kızılötesi1 ve kısa dalga kızılötesi2 bantların yeşil bant ile aritmetik işlemlerine dayanarak üretilen normalize kireçli sediment indeksi, normalize kil indeksi ve normalize çıplak toprak indekslerinin kullanımının araştırılması gerekebilir.


4.5.2.4. Kum içeriğinin çevresel değişkenlerle tahmini

Toprak kum içeriğine yönelik tahminde kullanılan model katsayıları ve model performans değerleri Çizelge 4.25'de verilmiştir. Belirleme katsayısı (R^2) 0.52, Kök

ortalama kare hatası (RMSE) %10.31 olarak belirlenmiştir. Model sonucunda önemli bulunan çevresel değişkenlere ait göreceli önem grafiği Şekil 4.35'te verilmiştir.

Çizelge 4.25. Kum içeriği tahmininde model değişken katsayıları

	R2:0.52	Hue ind.	Nor. Kır. Sediment İnd.	Nor. Çıp.Topr. İnd.
Kum	RMSE: %10.31	-19990.00	234.70	-166.80
	Nor.Kar. İnd.	Nor.Demir (FeO+2) İnd.	Norm. Demir İnd.	Norm. Kil İnd.
	1997.00	-35.51	-9.87	-474.00
	Norm. Bitki Fark İnd.	Parlaklık İndeksi	Satursayon İndeksi	Nor.Toprak Ayarlı Bitki İndeksi
	-965300.00	13.69	73.27	965300.00
	Üst Toprak Tane Büyüklük İnd.	Planform Eğriliği	Profil Eğriliği	Akış Gücü İndeksi
	-1739.00	-7.44	-1.45	0.03
	Topoğrafik Islaklık İndeksi	Eğim Uzunluğu	Bakı	Akış Doğrultusu
	-1.65	0.92	0.02	0.03
	Eğim (%)	Akış Birikim	Yükseklik	Kesişim Noktası
	-0.13	0.01	0.15	391600.00



Şekil 4.35. Kum içeriğinin tahmininde modelde kullanılan değişkenlerin önem seviyesi

Şekil 4.35 göz önünde alındığında kum içeriğinin tahmininde modelde en önemli değişken topoğrafik değişkenlerden olan yükseklik olmuştur. Yükseklikten sonra etkin değişkenler spektral verilerden üretilen çevresel değişkenler olmuştur. Poppiel vd.

(2021), Ortadoğu bölgesinde toprak kum içeriğinin haritasını oluşturdukları çalışmada eğitim seti için R^2 0.73, RMSE %12.1, test seti için R^2 :0.66 RMSE % 13.9 olarak belirlemişlerdir. Safanelli vd. (2020), Avrupa'da üst toprak özelliklerinin haritalanması için çıplak toprak kompozitlerini kullandığı çalışmada, kum (%) için eğitim setinde R^2 :0.66, RMSE %14.57, test setinde R^2 0.42 RMSE %19.26 sonuçlarını elde etmişlerdir. Mekânsal ve zamansal değişkenliği nedeniyle bazı kısıtlamalar olmasına rağmen uydu verilerinin, ekim alanlarının temel toprak özelliklerini haritalamak için kullanılabilir olduğunu bildirmektedirler. Forkuor vd. (2017), yaptıkları çalışmada kum içeriğinin tahmininde R^2 0.35, RMSE %7.57 değerini elde etmişlerdir. Mosleh vd. (2016), nispeten düz bir tarım ovasında yaptıkları çalışmada kum için R^2 0.06, RMSE %12.86 olarak belirlemişlerdir Adhikari vd. (2012), Danimarka'da farklı toprak derinliklerinde ince ve kaba kum fraksiyonlarının dağılımının eğim, yükseklik ve jeoloji tarafından kontrol edildiğini bildirmiştir. Xiao vd. (2006), Landsat ETM+ uydusunun kırmızı, yeşil ve mavi bantlarını kullanarak oluşturduğu üst toprak tane boyut indeksinin toprak kumunun ince fraksiyonlarıyla ilişkili olduğunu bildirmiştir. Çalışmada, aynı bantlar kullanılarak üretilen bu indis kum tahmininde önemli değişken olarak belirlenmiştir. Vaudour vd. (2019), Sentinel uydu görüntülerinin üst toprak özelliklerinin tahmin kapasitelerini araştırmak amacıyla yürüttüğü çalışmada, kum için R^2 0.03 ile 0.22 arasında, RMSE %8.17 ile 11.3 arasında belirlenmiştir. Sayısal toprak haritalamada Sentinel uydu görüntüleri arşivinin etkin şekilde kullanılabileceğini bildirmektedirler. Düz alanlar ve heterojen alanlar fark etmeksizin sonuçlarımız literatürlerce belirlenen değerlere yakın değer almıştır. Etkin olarak kullanılan indislere ek olarak toprak yüzeyinin çıplak olduğu dönemlerde üretilen toprak temelli indislerin kullanılabilirliğinin araştırılması önem arz etmektedir.

4.5.3. Temel bileşenler analizi

Toprak özellikleri ile çevresel değişkenler arasındaki mevcut ilişkileri anlamlandırabilmek ve yorumlayabilmek için temel bileşenler analizi yürütülmüştür. Bu analiz sırasında Kaiser-Mayer-Olkin (KMO) küresellik testi yapılmıştır. KMO değeri 0.503 olarak belirlenmiştir. Temel bileşenler analizi, Ortogonal rotasyon yöntemi (Varimax) ve öz değeri > 1 olan faktörler kullanılarak korelasyon matrisi baz alınarak yapılmıştır Faktör yükü, değişken ile temelde yatan ortak faktör arasındaki

ilişkiyi gösterir. Yüksek yüke sahip değişkenler, değişkenleri her faktör içinde birbirine bağlayan olası bir ortak temel faktör önermek için kullanılabilir. Faktör yüklerinin işaretleri, bu değişkenlerin nasıl ilişkili olduğu ve ortak faktörleri ne şekilde temsil ettikleri hakkında bilgi sağlar (Zeraatpisheh vd., 2019). Veri setimiz, aşağıdaki şekilde gruplandırılan 26 çevresel faktörü içermektedir: (i) topoğrafik özellikler, planform eğriliği, profil eğriliği, akış gücü indeksi, topoğrafik ıslaklık indeksi, bakı, akış doğrultusu, eğim (%), akış birikimi, yükseklik, (ii) uzaktan algılama değişkenleri, hue indeks, normalize kireçli sediment indeksi, normalize demir (FeO+2) indeksi, normalize demir indeksi, normalize kil indeksi, normalize fark bitki indeksi, parlaklık indeksi, üst toprak tane büyüklük indeksi ve (iii) toprak özellikleri, kil, silt, kum, pH, EC, organik madde, CaCO₃ eşdeğeri, KDK, Na. İstatistiksel analizler SPSS 23 (SPSS 23, 2015) kullanılarak yürütülmüştür.

Yürütülen analiz sonucunda Temel bileşenlerin sonuçları, seçilen toprak özelliklerinin değişkenliğini açıklamak için 9 ana bileşen oluşmuştur (Çizelge 4.26).

Çizelge 4.26. Temel bileşenler analizinin ilk dokuz bileşeninin varyans açıklama yüzdeleri

Bileşen	Özdeğer	% Varyans	Toplam Varyans (%)
1	4.237	16.296	16.296
2	3.357	12.911	29.208
3	2.847	10.951	40.158
4	2.246	8.638	48.796
5	2.057	7.911	56.708
6	1.868	7.186	63.894
7	1.511	5.813	69.707
8	1.222	4.702	74.408
9	1.026	3.946	78.355

İlk iki bileşenin (Bileşen 1 ve Bileşen 2) toplam değişkenliğin %29'undan fazlasını açıklayabilmektedir. Üçüncü bileşen dahil edildiğinde toplam varyansın %40'ı açıklanabilmektedir. Çizelge 4.27'de elde edilen bileşenler eklenmiş ve faktörler tanımlanmıştır.

Bu çalışmada dikkate alınan 26 faktörün ortak yönleri, bu 9 bileşenin ölçülen faktörlerin çoğundaki varyasyonun büyük bir bölümünü açıkladığını göstermektedir (Çizelge 4.27). Bileşen 1, toplam varyansın yaklaşık %16.30'unu açıklayabilmekte ve

alüvyal bir ovada, her ne kadar rakımsal olarak bölünmemiş olsa bile yükseklik değerinin öncelikle toprak fiziksel özelliklerinin ve bundan önemli derecede etkilenen toprak kimyasal özelliklerini etkilediğini açıklayabilmektedir. Alüvyal bir ovada yükseklik değerleri ile toprak özelliklerinin arasındaki ilişkiyi ortaya çıkarmak önemlidir.

Bileşen 2, toplam varyansın yaklaşık %12.9'unu açıklayabilmekte ve toprak organik maddesinin ve özellikle normalize fark bitki indeksi olmak üzere, uzaktan algılama değişkenleri tarafından büyük ölçüde katkıda bulunmaktadır (Çizelge 4.27). Bir kez daha, toprak organik maddesi ile uzaktan algılama değişkenleri arasındaki güçlü ilişkilerin mevcudiyetine işaret etmektedir (Zeraatpisheh vd., 2019). Mekânsal heterojenliği ölçmek amacıyla bir araç sağlamak için toprakların yüzey özelliklerini uzaktan algılanan görüntülerden elde edilen yansıma değerleri ile ilişkilendirmek kabul görmüş bir yaklaşımdır. Nitekim çalışılan uydu görüntüsün bitkisiz dönem olması göz önüne alındığında, doğal vejetasyondan ziyade tarımsal alanlardaki uygulamaları yansıması açısından da uzaktan algılama indekslerinin etkin şekilde kullanılabileceğini göstermektedir.

Bileşen 3, uzaktan algılama indekslerinin kendi aralarındaki ilişkilerinin önemli katkıları ile toplam varyansın yaklaşık %10.95'ini açıklayabilmektedir. Bileşen 4, Silt ve CaCO_3 eşdeğerinin ana materyal faktörü ile birlikte akış doğrultusu gibi topoğrafik bir etmenin birleşmesi mahiyetinde, kireçli ana materyalden ayrışıp, taşınarak birikmesinin bir sembolü olabilir. Faktörize etmek gerekirse, kireçli ana materyalin mevcut olduğu çevrede alüvyal bir ovanın oluşumunu tanımlayabilir. Bileşen 5, toplam varyansın yaklaşık %7.9'unu açıklar ve baskın olarak EC ve topoğrafik faktörlerin ortak katkısı bulunur. Bileşen 6, organik madde, topoğrafya ve spektral değişken katkılarıyla toplam varyansın yaklaşık %7.18'ini oluşturur. Bileşen 7, topoğrafik ıslaklık indeksi, akış gücü indeksi ve akış birikimi ile ilgili arazi şekli ortak değişkenlerinin önemli katkıları ile toplam varyansın yaklaşık %5.81'ini açıklayabilir. Geneli düz olan çalışma alanında erozyon göstergesi olabilecek topoğrafik indekslerin birikimi yansıtabilmesi açısından dikkate alınması gerekli bir durumdur. Bileşen 8, planform eğriliği ve profil eğriliği gibi eğrilik endekslerinden büyük ölçüde katkıda bulunarak toplam varyansın yaklaşık %4.70'ini açıklar. Bileşen 9, bakı ile toprak kimyasal özellikleri olan pH ve EC'nin katkıları ile toplam varyansın %3.94'ünü

açıklar. Gelen güneş açısının maruziyetine bağlı olarak yerel bir mikro iklim oluşabilir ve bu, toprak gelişimi üzerinde baskın olan makro iklimden daha güçlü etkilere sahip olabilir. Daha düşük ışık yoğunluğu ve buharlaşma değerleri genellikle güneşli yamaçlara göre gölgeli yamaçlarda gözlemlenir. Topraktaki donma ve çözülme arasındaki değişim de gölgeli yamaçlarda güneşli yamaçlara göre daha az sıklıkta görülür. Sonuç olarak, gölgeli yamaçlardaki topraklar daha güçlü ve daha derin su penetrasyonu sergileyebilir ve genellikle güneşli yamaçlardakilere göre daha derin bir şekilde gelişebilir. Bununla birlikte, daha soğuk ve gölgeli yamaçlarda ayrışma yoğunluğu daha düşük olabilir (Blume vd., 2016). Tüm bu etkileri sebebi ile bakı ile toprak kimyasal özellikleri arasındaki ilişki kayda değerdir ve farklı topoğrafik alanlardaki çalışmalarda kullanılması önem arz etmektedir. Yedinci ve sekizinci bileşenler esas olarak topoğrafik özellikleri içerir ve toprak özellikleri ile ilişkili değildir.

Çalışmamızda, temel bileşenler analizinin sonuçları, ilk 9 bileşenin toprak özelliklerindeki toplam değişkenliğin yaklaşık %78'ini tanımlayabildiğini göstermektedir. Toprak organik maddesi, uzaktan algılama değişkenleriyle oldukça ilişkilidir. Bununla birlikte ana materyal ve topoğrafyanın birlikte etkisinin yansıtılması açısından benzer ana materyal ve topoğrafik faktörlerin hâkim olduğu alanlarda akış doğrultusu değişkeninin kullanımının toprak özelliklerinin değişkenliğinin açıklanabilmesi açısından başarılı olacağı değerlendirilmiştir.

Çizelge 4.27. Temel bileşenler analizi sonucu elde edilen bileşenlerin faktör yükleri

	Bileşenler								
	1	2	3	4	5	6	7	8	9
Hue indeks						-0.680			0.442
Nor. Kireçli Sediment İndeksi			-0.901						
Nor. Demir(FeO+2) İndeksi		-0.896							
Normalize Demir İndeksi	0.301	.318	0.727			-0.304			
Normalize Kil İndeksi		0.850							
Normalize Bitki Fark İndeksi		0.749	-0.332			0.367			
Parlaklık İndeksi	-0.342		0.745						
Üst Toprak Tane Büy. İnd.			-0.455	-0.365		-0.617			
Kil	0.899								
Silt				0.858					
Kum	-0.825			-0.355					
pH	0.307			0.436					-0.552
EC	0.456				-0.508				0.356
Organik Madde		0.379				0.575			
CaCO ₃ eşdeğeri				0.847					
KDK	0.918								
Na						0.612			
Planform Eğriliği								-0.884	
Profil Eğriliği								0.860	
Akış Gücü İndeksi					.541		0.693		
Topografik Islaklık İndeksi							0.801		
Bakı									-0.730
Akış Doğrultusu				-0.350		0.501			
Eğim (%)					.880				
Akış Birikim							0.872		
Yükseklik	-0.394				.658				

5. SONUÇ VE ÖNERİLER

Topraklar, oluştukları çevreden ayrılamaz ve çevreleriyle birlikte topraklar, pedojenik ve jeomorfolojik süreçlerin etkileşimi yoluyla gelişir. Arazi konumu ile toprak tipindeki farklılıklar genellikle toprak oluşumunu etkileyen akış, erozyon ve birikme süreçlerindeki farklılıklara atfedilir. Kurak ve yarı kurak alanlarda yapılan çeşitli çalışmalar, toprakların ana materyal, arazi yüzeyinin yaşı, topoğrafya, su dağılımı, yağış miktarı ve yoğunluğu ve bitki heterojenitesindeki farklılıklardan kaynaklanan geniş bir mekânsal değişkenliğe sahip olduğunu göstermektedir. Bu çeşitlilikte bir yapıyı tanımlamak ve sınıflandırmak için geleneksel toprak etüt haritalama yöntemleri ile çalışmalar sürdürülmeye devam etmektedir.

Geleneksel toprak etüt ve haritalama çalışmaları sonucu üretilen nihai toprak haritalarında bulunan toprak haritalama birimleri ve haritalama üniteleri, coğrafi bilgi sistemleri teknolojileri kullanılarak vektör veri tipinde üretilmekte ve depolanmaktadır. Nitekim baskı halinde kartografik olarak toprak haritalarının kullanımı güncelliğini korumaktadır.

Modern tarımsal uygulamalara hizmet etmek amacıyla hassas bir şekilde kaydedilmiş veya üretilmiş verilere ihtiyaç vardır. Sayısal toprak haritalama neticesinde matematiksel ve istatistiksel esaslara dayalı ve tahmin belirsizliklerini de içerecek şekilde üretilen raster tabanlı dijital toprak haritaları, mekânsal özgüllük sorununa sahip olan haritalama ünitesi sınırları vektörize şekilde gösterilen geleneksel toprak haritalarına göre gelecekteki dijital tarım teknolojilerinde daha etkin kullanım olanağı sunabileceği için tercih edilmelidir.

Gelişen tarım teknolojilerine girdi sağlayacak düzeyde toprak bilgisi üretebilecek sayısal toprak haritalama metodolojilerin geliştirilmesi, birçok alanda karar verme ve yönetimde kullanılan dijital verilerle entegrasyonu sağlayabilmek açısından önemlidir.

Sayısal toprak haritalama sunduğu matematiksel dayanakla birlikte öznel yaklaşımdan nesnellığe ve dijital teknolojilerin gelişmesi ile birlikte hızlı ve tekrarlanabilir toprak haritaları üretilbilmesine olanak sağlar. Sayısal toprak haritalamada etkin rol oynayan

toprak bilimciler, sayısal toprak haritalamanın daha hızlı ve güvenilir, sonuç odaklı gelişimine büyük katkıda bulunabilirler.

Türkiye’de toprak etütlerinin çoğu geleneksel yöntemlerle ve eski sınıflandırma sistemlerinde küçük ölçekli gerçekleştirilmiştir. Bununla birlikte bazı alanlar henüz detaylı ölçekte haritalandırılmamıştır. Son zamanlarda, tarımsal ve tarım dışı toprak bilgisi ihtiyacı olan sektörler karar verme sürecinde yüksek kaliteli toprak haritalarına daha fazla ihtiyaç duymaktadır.

Çalışma alanı olarak seçilen bölge, normal şartlarda geleneksel toprak etüt haritalama yöntemleri ile dahi sınıflandırılması zor bir alan olan alüvyal ve kolüvyal etkilerin birlikte hüküm sürerek oluşturduğu bir tarım ovasıdır.

Çalışmada Sayısal toprak haritalama literatürünün dünya genelinde nereden gelip, ne tarafa doğru yöneldiği detaylıca araştırılmış gerek toprak sınıflarının tahmininde gerekse de toprak özelliklerinin tahminine yönelik detaylı literatür araştırması sonucunda mevcutta bulunan etkin yöntemler çalışılmış ve denenmiştir.

Denetimli sınıflandırma algoritması kullanılarak toprak sınıflarının haritalanması kapsamında ordo düzeyinde eğitim setinde %65 test setinde %59, alt ordo düzeyinde eğitim setinde %60, test setinde %62, büyük grup düzeyinde eğitim setinde %56, test setinde %51, alt grup düzeyinde eğitim setinde %50, test setinde %40, seri düzeyinde eğitim setinde %31, test setinde %26, FAO dünya referans sistemi 2. düzeyinde eğitim setinde %52, test setinde %48 olarak belirlenmiştir. Yarı kurak alanlarda yapılan benzer çalışmalarla kıyaslandığında doğruluk değerlerinin literatürle benzer sonuçlar içerdiği sonucuna varılmıştır.

Ordo düzeyinde sınıflandırma modelinde göreceli önemi yüksek olan Literatürde az kullanılan Normalize Kireçli Sediment İndeksi ve Parlaklık indeksi spektral değişkenlerinin farklı alanlarda çalışılması toprak farklılıklarını yansıtabilecek yeni ortak değişkenlerin geliştirilmesi bakımından sayısal toprak haritalama literatüründe önem arz etmektedir.

Alt ordo düzeyinde çalışma alanında iklime ait çevresel değişken mekânsal varyasyonunu yansıtacak düzeyde veri sağlanamaması sebebiyle kullanılmamıştır. Gelişen teknolojik ilerlemelerle birlikte birçok alanda veri kaydetmeye başlayan gezici meteoroloji istasyonlarının mevcudiyeti, bu verilerin eldesi yoluyla alt ordo ayrımlarında mikro klimayı yansıtabilecek düzeyde veri elde edilmesini kolaylaştıracaktır.

Büyük grup ve alt grup sınıfları USDA toprak sınıflandırma sisteminde arazi gözlemlerine ve morfolojik tanımlamaların sınıf ayrımında önemli düzeyde kullanıldığı kategorilerdir. Bu kapsamda özellikle bu düzeyde sayısal toprak haritalamanın doğruluğunu ve etkinliğini artırmak amacıyla arazi gözlemlerinin yersel spektrometrik veriler aracılığı ile sayısal çevresel değişken olarak kullanılması önemlidir.

Ordo düzeyinden alt grup düzeyine kadar çalışma alanı göz önüne alındığında topoğrafik değişkenlerin sınıflandırma modellerinde etkinliği düşük kalmıştır. Topoğrafyanın USDA toprak sınıflandırma sisteminde ordo düzeyinden alt grup düzeyine kadar etkin olamadığının göstergesi olması açısından sayısal toprak haritalamada bu sonuçların paylaşılması gerekmektedir.

Seri düzeyinde modelde etkin olan topoğrafik değişkenler planform eğriliği, profil eğriliği, topoğrafik ıslaklık indeksi ve akış gücü indeksi olarak belirlenmiştir. Bu değişkenlerin arazi yönetim uygulamaları açısından en detaylı bilgiyi içeren seri düzeyinde sayısal toprak haritalama çalışmalarında farklı alanlarda çalışılması etkinliklerinin tam olarak belirlenebilmesi açısından önemlidir.

Denetimsiz sınıflandırma algoritması sonucu ordo düzeyinde genel doğruluk %43, büyük grup düzeyinde ise %18 olarak belirlenmiştir. K değerinin 8,10 ve 20 olması durumlarında algoritma çalışma alanı için mevcut toprak haritası ile uyumlu kümeler oluşturamamıştır.

Sayısal toprak haritalama gelişmeye devam eden bir bilim dalıdır. Özellikle makine öğrenme algoritmalarının bu alanda hala bilgi keşfetme aracı olarak kullanılmaktadır. Sayısal haritalama çalışması öncesi pedolojik bilgi ile sağlam bir entegrasyon

sağlanmalı, çalışma sonunda sonuçlar pedolojik olarak yorumlanmalı ve sonuçları paylaşılmalıdır.

Programlama dili R, son birkaç on yıldır toprak biliminde yaygın olarak kullanılmaktadır. Toprak biliminde temel veri analizinden spesifik uygulamalara kadar kullanımda kendine geniş yer bulmasıyla birlikte özellikle sayısal toprak haritalama konusunda etkin paketleri ve uygulamaları mevcuttur. Nitekim buna yönelik kişi ve kurumlarca öğretici kitaplarda yazılmıştır. Tezde ele alınan temel istatistiksel analizler, modelleme, mekânsal analiz ve sayısal toprak haritalama yöntemlerinin yürütülmesinde R programı etkin olarak kullanılmıştır. R yazılımının CBS ile entegrasyonu, benzer alanlardaki toprak sınıflarını tahmin etme fırsatı sağlar. CBS tabanlı yazılımlar ve R gibi güçlü istatistiksel yazılımlar, toprak etüt ve haritalama sürecini sayısal olarak yapma yaklaşımımızı destekleyebilir.

Özellikle toprak sınıflarının tahmini ve haritalanmasına yönelik kısımda metotların fazlalığı bizleri en temel algoritmalarından birisi ile çalışmaya yöneltmiştir. Bu kapsamda lojistik regresyon modelleri iyi bilinir, kavramsal olarak basittir ve yorumlanması kolaydır; bu nedenle sayısal toprak haritalarının hazırlanması için kullanımları uygun görünmektedir. Sonuçlarımıza göre, güvenilir ve esnek bir yaklaşım olarak, çok terimli lojistik regresyon, mekânsal sayısal toprak haritalarını hazırlamak için başarıyla kullanılabilir. Kullanılan modele ait katsayı bilgileri açık veri paylaşımı ilkesi doğrultusunda tez içeriğinde verilmiştir. Türkiye’de benzer iklim koşulları altında çalışılmasını önemle önerilmektedir.

Sınıflandırma algoritmalarının ve uygulama alanının özellikle matematik ve istatistik bilimlerinin yanı sıra bilgisayar teknolojisi temelli disiplinlerden katkıya açık olduğu bilinen bir gerçektir. Bu kapsamda toprak sınıflarının tahmininde ileri makine öğrenme algoritmalarının kullanımında model oluşturma ve matematiksel temelde farklı bilim alanları ile multidisipliner çalışmaların önemini bildiriyoruz.

Sayısal toprak haritalama çalışmalarında araziye dair veri bulunmadığı durumlarda, arazi öncesi bilgiyi en yüksek seviyeye çıkarmak amaçlı çevresel değişkenlerin anlamlı kümelerinin arazide toprak birimlerine karşılık gelebilir mi sorusuna aradığımız cevap neticesinde en yaygın kümeleme algoritması olarak kullanılan k-

ortalama sonuçları, alüvyal bir tarım ovasında yorumlanabilirlik açısından etkinliği düşük bulunmuştur. Mevcut olan ve giderek artmaya devam eden dijital çevresel değişkenlerden anlamlı toprak verilerinin ayırımına dair umut vaat eden algoritma üzerine daha fazla çalışılmasını önemle önerilmektedir. Özellikle haritalama ünitelerinden oluşan eski toprak verilerinin ayrıştırılması konusunda k ortalama algoritmasının ve bulanık k ortalama algoritmalarının etkinliğinin araştırılması önem arz etmektedir.

Elde edilen veri setlerinden uzman temelli yaklaşımın hem zaman alan bir yaklaşım hem de öznelliğe yönelimi dolayısı ile kendi çalışma alanımızda kullanımının zor olduğunu ifade edilebilir. Nitekim sayısal toprak haritalama literatürüne tamamen hâkim olmak amacıyla bu yönteminde mevcut bir alanda çalışılması ve sonuçlarının paylaşılması önem arz etmektedir.

Denetimli ve denetimsiz sınıflandırma yöntemlerinin toprak sınıflarının sayısal olarak haritalanması amacıyla karşılaştırılmak istenirse, denetimli makine öğrenme algoritması olan çok terimli lojistik regresyon ile üretilen haritaların doğruluk değerleri ve tematik haritalar göz önüne alındığında daha başarılı olduğu belirlenmiştir.

Toprak özelliklerinin tahmini, regresyon yaklaşımını temel alan bir metodoloji içermektedir. Bu kapsamda bu modellerin veya daha ileri makine öğrenme algoritmalarını kullanarak toprak özelliklerinin yüksek doğrulukta mekânsal tahmini ve haritalarının üretilebilmesi bu özelliklerin dikkate alınarak tarımsal faaliyetlerin yürütülmesinde önem arz etmektedir. Bu kapsamda alüvyal bir ovada kil, kum, katyon değişim kapasitesi ve organik madde için oluşturulan tahmin modellerinin farklı makine öğrenme algoritmaları ile tahminlerinin karşılaştırılmasına yönelik çalışmalar yapılabilir.

Toprak özellikleri ile çevresel değişkenler arasındaki ilişkilerin araştırılması sonucunda çalışma alanında toprak organik maddesinin spektral çevresel değişkenlerle faktörlenebilir düzeyde ilişkili olduğu, düz bir alüvyal ova olan çalışma alanında topoğrafik değişkenlerinde toprak özelliklerinin dağılımında etkili olduğu sonucuna varılmıştır. Araziden elde edilen yüzey toprak özellikleri ile toprak sınıflarını tahmin

etmeye yönelik kullanılan çevresel değişkenlerin arasında temel bileşenler analizinin yürütülmesi seri düzeyinde çalışma alanında çevresel değişkenlerin göreceli önem düzeylerinin yorumlanmasında kolaylık sağlamıştır. Bu kapsamda eski toprak haritalarının eğitim verisi olarak kullanılacağı çalışmalarda arazi yönetimi faaliyetlerinin toprak değişikliğine neden olabileceği alanlarda bu metodolojinin kullanımı alt düzey toprak sınıflarının arazi kullanımı ile ilişkilerini de ortaya koyabilmesi açısından faydalı olduğu sonucuna varılmıştır.

Farklı toprak sınıflarındaki örneklerin boyutu ve mekânsal dağılımı, sayısal toprak haritalarının kalitesini ve doğruluğunu büyük ölçüde etkilemektedir. Bu nedenle veri seti hazırlanması ve dengesiz sınıf dağılımları konularında makine öğrenme algoritmalarının çalıştırılmadan önce dikkat edilmesi gerekli hususlardır.

Üretilen toprak sınıfı tahmin modellerinin benzer alanlarda uygulanabilirliğine ve modellerin kalibrasyonunun etkin şekilde yapılabilmesi üzerine çalışmalara odaklanılması gerekmektedir. Özellikle toprakların kullanımı ve yönetimi ile ilgili birçok karar verme işleminde önem arz eden alt düzey toprak sınıflandırma seviyelerinin tahminine yönelik çalışmaların yapılması önerilmektedir.

KAYNAKLAR

- Abdel-Kader, F. H. (2011). Digital soil mapping at pilot sites in the northwest coast of Egypt: A multinomial logistic regression approach. *The Egyptian Journal of Remote Sensing and Space Science*, 14(1), 29-40. doi.org/10.1016/j.ejrs.2011.04.001.
- Adhikari, K., Kheir, R. B., Greve, M. B., Bøcher, P. K., Malone, B. P., Minasny, B. & Greve, M. H. (2013). High-resolution 3-D mapping of soil texture in Denmark. *Soil Science Society of America Journal*, 77(3), 860-876. doi.org/10.2136/sssaj2012.0275.
- Afshar, F. A., Ayoubi, S. & Jafari, A. (2018). The extrapolation of soil great groups using multinomial logistic regression at regional scale in arid regions of Iran. *Geoderma*, 315, 36-48. doi.org/10.1016/j.geoderma.2017.11.030.
- Agren, A. M., Lidberg, W., Strömberg, M., Ogilvie, J. & Arp, P. A. (2014). Evaluating digital terrain indices for soil wetness mapping—a Swedish case study. *Hydrology and Earth System Sciences*, 18(9), 3623-3634. doi:10.5194/hess-18-3623-2014.
- Aitkenhead, M. J., & Coull, M. C. (2019). Digital mapping of soil ecosystem services in Scotland using neural networks and relationship modelling—Part 1: Mapping of soil classes. *Soil Use and Management*, 35(2), 205-216. doi.org/10.1111/sum.12492.
- Akgül, M., Başayığit, L., Uçar, Y. & Müjdecı, M. (2001). *Atabey Ovası Toprakları*. S.D.Ü. Ziraat Fakültesi Yayınları.
- Akpa, S. I., Odeh, I. O., Bishop, T. F. & Hartemink, A. E. (2014). Digital mapping of soil particle-size fractions for Nigeria. *Soil Science Society of America Journal*, 78(6), 1953-1966. doi.org/10.2136/sssaj2014.05.0202.
- Aksoy, E. (2011). *Toprak Haritalamada Pedolojik ve Coğrafi Değişkenler Arasındaki İlişkinin Sayısal Ortamda Belirlenmesi: Tekirova Örneği*. (Doktora Tezi, Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü)
- Aksoy, E. & Dirim, M. S. (2009). Soil mapping approach in GIS using Landsat satellite imagery and DEM data. *African Journal of Agricultural Research*, 4(11), 1295-1302.
- Allison, L. E. & Moodie, C. D. (1965). Carbonate volumetric calcimeter method. In: Black, C.A. (Ed.), *Methods of Soil Analysis. Agronomy Monographs: 9. Part 2*. ASA, Madison, Wisconsin.
- Alpaydın, E. (2010). *Introduction to Machine Learning*. MIT Press, Cambridge, MA, USA.
- Anonim, (2021). USGS EROS Archive - Landsat Archives - Landsat 7 Enhanced Thematic Mapper Plus (ETM+) Level-1 Data Products

(<https://www.usgs.gov/centers/eros/science/usgs-eros-archive-landsat-archives-landsat-7-enhanced-thematic-mapper-plus>) (Son erişim tarihi: 10.04.2021)

- Asgari, N., Ayoubi, S., Jafari, A. & Demattê, J. A. (2020). Incorporating environmental variables, remote and proximal sensing data for digital soil mapping of USDA soil great groups. *International Journal of Remote Sensing*, 41(19), 7624-7648. doi.org/10.1080/01431161.2020.1763506.
- Assami, T. & Hamdi-Aïssa, B. (2019). Digital mapping of soil classes in Algeria–A comparison of methods. *Geoderma Regional*, 16, e00215. doi.org/10.1016/j.geodrs. 2019.e00215.
- Atatanır, L. (2004). *IKONOS sayısal uydu verilerinin detaylı toprak haritalarının hazırlanmasında kullanıma olanaklarının Ege bölgesinde seçilen örnek bir alanda araştırılması*. (Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü)
- Ballabio, C., Panagos, P., & Monatanarella, L. (2016). Mapping topsoil physical properties at European scale using the LUCAS database. *Geoderma*, 261, 110-123. doi.org/10.1016/j.geoderma.2015.07.006.
- Başayığıt, L. & Dinç, U., (2001). *Toprak Etüd ve Haritalama Çalışmalarında Bilgisayar Teknolojilerinin Kullanımı*. Tarımda Bilişim Teknolojileri 4. Sempozyumu. Kahramanmaraş, 283-291.
- Başayığıt, L. & Senol, S. (2008). Comparison of soil maps with different scales and details belonging to the same area. *Soil Water Research*, 3(1), 31-39.
- Başayığıt, L., Akgul, M. & Senol, H. (2009). Estimation of Different Soil Properties by Using Reflectance Values of TERRA-ASTER Bands. *Asian Journal of Chemistry*, 21(2), 1137-1144.
- Başayığıt, L., Dedeoglu, M. & Demir, S. (2017). Digital mapping of Histosols using LANDSAT 7 ETM+ in Isparta, Turkey. *In Global Soil Map-Digital Soil Mapping from Country to Globe*, 113-119. CRC Press.
- Başayığıt, L., Öztekin, M. Ö., Dingil, M., Şenol, S. & Dinç U. (1998). *Detail Soil Mapping of The Adıyaman-Kahta Irrigation Project Area Using Digital Satellite Data*. International Symposium on Arid Region Soil. September 21-24, İzmir, 529-532.
- Batjes, N. H. (2008). ISRIC-WISE Harmonized Global Soil Profile Dataset (Ver. 3.1.). Report 2008/02, ISRIC-World Soil Information, Wageningen.
- Batjes, N. H. (2009). Harmonized soil profile data for applications at global and continental scales: updates to the WISE database. *Soil Use and Management*, 25(2), 124-127. doi.org/10.1111/j.1475-2743.2009.00202.x.

- Beaudette, D. E. & O'Geen, A. T. (2009). Quantifying the Aspect Effect: An Application of Solar Radiation Modeling for Soil Survey. *Soil Science Society of America Journal*, 73, 1345-1352. doi.org/10.2136/sssaj2008.0229.
- Behrens, T., & Scholten, T. (2006). A comparison of data-mining techniques in predictive soil mapping. In *Developments in Soil Science* 31, 353-617. Elsevier. doi.org/10.1016/S0166-2481(06)31025-2.
- Behrens, T., Zhu, A.X., Schmidt, K. & Scholten, T. (2010). Multi-scale digital terrain analysis and feature selection for digital soil mapping. *Geoderma*, 155(3-4), 175-185. doi.org/10.1016/j.geoderma.2009.07.010.
- Behrens, T., Förster, H., Scholten, T., Steinrücken, U., Spies, E. D. & Goldschmitt, M. (2005). Digital soil mapping using artificial neural networks. *Journal of plant nutrition and soil science*, 168(1), 21-33. doi.org/10.1002/jpln.200421414.
- Berkman, E. T. & Reise, S. P. (2012). *A conceptual guide to statistics using SPSS*. Sage Publishing, New Delhi.
- Blume, H. P., Brümmer, G. W., Fleige, H., Horn, R., Kandeler, E., Kögel-Knabner, I. & Wilke, B. M. (2016). Soil development and soil classification. In *Scheffer/Schachtschabel Soil Science*, 285-389. Springer, Berlin, Heidelberg.
- Bodaghabadi, M. B., Martínez-Casasnovas, J. A., Borujeni, I. E., Salehi, M. H., Mohammadi, J. & Toomanian, N. (2016). Database extension for digital soil mapping using artificial neural networks. *Arabian Journal of Geosciences*, 9(18), 1-13. doi.org/10.1007/s12517-016-2732-z.
- Boettinger, J. L. (2010). Environmental covariates for digital soil mapping in the western USA. In *Digital Soil Mapping*, 17-27. Springer, Dordrecht. doi.org/10.1007/978-90-481-8863-5_2.
- Boettinger, J. L., Ramsey, R. D., Bodily, J. M., Cole, N. J., Kienast-Brown, S., Nield, S. J. & Stum, A. K. (2008). Landsat spectral data for digital soil mapping. In *Digital soil mapping with limited data*, 193-202. Springer, Dordrecht. doi.org/10.1007/978-1-4020-8592-5_16.
- Bouyoucos, G. J. (1962). Hydrometer method improved for making particle size analysis of soils. *Agronomy Journal*, 54, 464-465. doi.org/10.2134/agronj1962.00021962005400050028x.
- Brown, K. S., Libohova, Z. & Boettinger, J. (2017). Digital Soil Mapping. In C. Ditzler, K. Scheffe, and H.C. Monger (eds.) *Soil survey manual*, USDA Handbook 18 295-354, Government Printing Office, Washington, D.C.
- Browning, D. M. & Duniway, M. C. (2011). Digital soil mapping in the absence of field training data: A case study using terrain attributes and semiautomated soil signature derivation to distinguish ecological potential. *Applied and Environmental Soil Science*, 2011, 421904. doi.org/10.1155/2011/421904.

- Brungard, C. W., Boettinger, J. L., Duniway, M. C., Wills, S. A., & Edwards Jr, T. C. (2015). Machine learning for predicting soil classes in three semi-arid landscapes. *Geoderma*, 239, 68-83. doi.org/10.1016/j.geoderma.2014.09.019.
- Brus, D. J., De Gruijter, J. J. & Van Groenigen, J. W. (2006). Designing spatial coverage samples using the k-means clustering algorithm. *Developments in Soil Science*, 31, 183-192. doi.org/10.1016/S0166-2481(06)31014-8.
- Bulmer, C., Schmidt, M. G., Heung, B., Scarpone, C., Zhang, J., Filatow, D. & Smith, S. (2016). Improved soil mapping in British Columbia, Canada, with legacy soil data and random forest. In *Digital Soil Mapping Across Paradigms, Scales and Boundaries*, 291-303. Springer, Singapore. doi:10.1007/978-981-10-0415-5_24.
- Burrough, P. A., van Gaans, P. F. M. & Hootsmans, R. (1997). Continuous Classification in Soil Survey: Spatial Correlation, Confusion and Boundaries. *Geoderma*, 77, 115-35. doi:10.1016/S0016-7061(97)00018-9.
- Camera, C., Zomeni, Z., Noller, J. S., Zissimos, A. M., Christoforou, I. C. & Bruggeman, A. (2017). A high resolution map of soil types and physical properties for Cyprus: A digital soil mapping optimization. *Geoderma*, 285, 35-49. doi.org/10.1016/j.geoderma.2016.09.019.
- Carré, F. & McBratney, A. B. (2005). Digital terrain mapping. *Geoderma*, 128(3-4), 340-353. doi.org/10.1016/j.geoderma.2005.04.012.
- Chabrillat, S., Ben-Dor, E., Cierniewski, J., Gomez, C., Schmid, T. & van Wesemael, B. (2019). Imaging spectroscopy for soil mapping and monitoring. *Surveys in Geophysics*, 40(3), 361-399. doi.org/10.1007/s10712-019-09524-0.
- Chagas, C. D. S., Carvalho Júnior, W. D., Pinheiro, H. S. K., Xavier, P. A. M., Bhering, S. B., Pereira, N. R. & Calderano Filho, B. (2018). Mapping soil cation exchange capacity in a semiarid region through predictive models and covariates from remote sensing data. *Revista Brasileira de Ciência do Solo*, 42. doi.org/10.1590/18069657rbc20170183.
- Cherlinka, V. (2017). Using geostatistics, DEM and remote sensing to clarify soil cover maps of Ukraine. In *Soil Science Working for a Living*, 89-100. Springer, Cham. doi.org/10.1007/978-3-319-45417-7_7.
- Cherlinka, V., Dmytruk, Y. & Barabas, D. (2019). Methods of verification of soils prediction maps: a case study from Chernivtsi region, Ukraine. *Geographia Cassoviensis*, 13(2), 141-160. doi.org/10.33542/GC2019-2-04.
- Cole, N. J. & Boettinger, J. L. (2007). A pedogenic understanding raster classification methodology for mapping soils, Powder River Basin, Wyoming, USA. In P. Lagacherie, A.B. McBratney, and M. Voltz (eds.) *Digital soil mapping: An introductory perspective*. *Developments in Soil Science*, 31, 377-388. Elsevier, Amsterdam.

- Collard, F., Kempen, B., Heuvelink, G. B., Saby, N. P., de Forges, A. C. R., Lehmann, S. & Arrouays, D. (2014). Refining a reconnaissance soil map by calibrating regression models with data from the same map (Normandy, France). *Geoderma Regional*, 1, 21-30. doi.org/10.1016/j.geodrs.2014.07.001.
- Congalton, R. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35– 46. doi.org/10.1016/0034-4257(91)90048-B.
- Congalton, R. G. & Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press.
- Çağlar, K. Ö. (1951). *Eskişehir ve Alpu Ovaları Toprakları*, A.Ü. Ziraat Fakültesi Yayınları.
- ÇEM, (2018). Toprak Organik Karbonu Projesi, Teknik Özet, Çölleşme ve Erozyonla Mücadele Genel Müdürlüğü. 32s.
- Da Silva Chagas, C., de Carvalho Junior, W., Bhering, S. B. & Calderano Filho, B. (2016). Spatial prediction of soil surface texture in a semiarid region using random forest and multiple linear regressions. *Catena*, 139, 232-240. doi.org/10.1016/j.catena.2016.01.001.
- De Castro Padilha, M. C., Vicente, L. E., Demattê, J. A., Loebmann, D. G. D. S. W., Vicente, A. K., Salazar, D. F. & Guimarães, C. C. B. (2020). Using Landsat and soil clay content to map soil organic carbon of oxisols and Ultisols near São Paulo, Brazil. *Geoderma Regional*, 21, e00253. doi.org/10.1016/j.geodrs.2020.e00253.
- Debella-Gilo, M. & Etzelmüller, B. (2009). Spatial prediction of soil classes using digital terrain analysis and multinomial logistic regression modeling integrated in GIS: Examples from Vestfold County, Norway. *Catena*, 77(1), 8-18. doi.org/10.1016/j.catena.2008.12.001.
- Dedeoğlu, M. (2017). *Sarayönü Beşgözler K.O.P. Alanı Detaylı Toprak Etüdü ve Farklı Yöntemlerle Arazi Değerlendirmesi*. (Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü)
- Demattê, J. A., Safanelli, J. L., Poppiel, R. R., Rizzo, R., Silvero, N. E. Q., de Sousa Mendes, W. & da Silva Lisboa, C. J. (2020). Bare earth's Surface Spectra as a proxy for Soil Resource Monitoring. *Scientific reports*, 10(1), 1-11. doi.org/10.1038/s41598-020-61408-1.
- Dinç, U., Kapur, S., Özbek, H. & Şenol, S. (1987). *Toprak Genesisi ve Sınıflandırılması*. Çukurova Üniversitesi Yayınları.
- Dobarco, M. R., McBratney, A., Minasny, B. & Malone, B. (2021). A modelling framework for pedogenon mapping. *Geoderma*, 393, 115012. doi.org/10.1016/j.geoderma.2021.115012.

- Dobos, E. & Hengl, T. (2009). Soil mapping applications. *In Developments in soil science*, 33, 461-479. Elsevier. doi.org/10.1016/S0166-2481(08)00020-2.
- Dotto, A. C., Demattê, J. A. M., Viscarra Rossel, R. A. & Rizzo, R. (2020). Soil environment grouping system based on spectral, climate, and terrain data: a quantitative branch of soil series, *SOIL*, 6, 163–177, doi.org/10.5194/soil-6-163-2020.
- Douaoui, A., Nicolas, H. & Walter, C. (2006). Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*, 134(1-2), 217-230. doi.org/10.1016/j.geoderma.2005.10.009.
- Du Plessis, C., Van Zijl, G., Van Tol, J. & Manyevere, A. (2020). Machine learning digital soil mapping to inform gully erosion mitigation measures in the Eastern Cape, South Africa. *Geoderma*, 368, 114-287. doi.org/10.1016/j.geoderma.2020.114287.
- Du, F., Zhu, A., Liu, J. & Yang, L. (2020). Predictive mapping with small field sample data using semi-supervised machine learning. *Transactions in GIS*, 24, 315-331. doi.org/10.1111/tgis.12598.
- Duda, R. O., Hart, P. E. & Stork, D. G. (2001). Pattern classification. John Wiley & Sons, New York, NY.
- Durgun, B., Uygur, V., Durgun, B. & Sukuşu, E. (2017). Isparta-Atabey ovası topraklarında mikro element yayırlılığı ile toprak özellikleri arasındaki ilişkilerin temel bileşen analizi ile belirlenmesi. *Anadolu Tarım Bilimleri Dergisi*, 32(2), 258-268. doi.org/10.7161/omuanajas.321115.
- ESA, (2015). *Sentinel-2 User Handbook*. European Space Agency. 64 p.
- Esetlili, M. T., Kurucu, Y., Özden, N., Şanlı, F. B., Özen, F. & Bolca, M. (2020). Stereo Foto Yorumlama Teknikleri ile Toprak Etüd ve Haritalama Çalışmalarında Multispektral Verilerin Katkısı. *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 140-150. doi:10.20289/zfdergi.695768.
- Esfandiarpour-Boroujeni, I., Shamsabadi, M. S., Shirani, H., Mosleh, Z., Bodaghabadi, M. B. & Salehi, M. H. (2020a). Comparison of error and uncertainty of decision tree and learning vector quantization models for predicting soil classes in areas with low altitude variations. *Catena*, 191, 104581. doi.org/10.1016/j.catena.2020.104581
- Esfandiarpour-Boroujeni, I., Shamsabadi, M. S., Shirani, H., Mosleh, Z., Bagheri-Bodaghabadi, M. & Salehi, M. H. (2020b). Assessment of different digital soil mapping methods for prediction of soil classes in the Shahrekord plain, Central Iran. *Catena*, 193, 104648. doi.org/10.1016/j.catena.2020.104648.
- FAO, (1998). *World reference base for soil resources*. 3rd edition. Food & Agriculture Org. Rome.

- FAO, (2018). *Soil Organic Carbon Mapping Cookbook*, 2nd edition, Rome.
- Florinsky, I. V. (2016). Calculation Methods. In *Digital Terrain Analysis in Soil Science and Geology* (Second Edition), 109-147. Academic Press, doi.org/10.1016/B978-0-12-804632-6.00004-3.
- Fongaro, C. T., Demattê, J. A., Rizzo, R., Lucas Safanelli, J., Mendes, W. D. S., Dotto, A. C. & Ustin, S. L. (2018). Improvement of clay and sand quantification based on a novel approach with a focus on multispectral satellite images. *Remote Sensing*, 10(10), 1555. doi.org/10.3390/rs10101555.
- Forghani, S. J., Pahlavan-Rad, M. R., Esfandiari, M. & Torkashvand, A. M. (2020). Spatial prediction of WRB soil classes in an arid floodplain using multinomial logistic regression and random forest models, south-east of Iran. *Arabian Journal of Geosciences*, 13(13), 1-11. doi.org/10.1007/s12517-020-05576-4.
- Forkuor, G., Hounkpatin, O. K., Welp, G., & Thiel, M. (2017). High resolution mapping of soil properties using remote sensing variables in south-western Burkina Faso: a comparison of machine learning and multiple linear regression models. *PloS one*, 12(1), e0170478. doi.org/10.1371/journal.pone.0170478.
- Gad, S. & Kusky, T. (2006). Lithological mapping in the Eastern Desert of Egypt, the Barramiya area, using Landsat thematic mapper (TM). *Journal of African Earth Sciences*, 44(2), 196-202. doi.org/10.1016/j.jafrearsci.2005.10.014.
- Gardi, C. & Yigini, Y. (2012). Continuous Mapping of Soil pH Using Digital Soil Mapping Approach in Europe. *Eurasian Journal of Soil Science*, 1(2), 64-68.
- Gentleman, R. & Lang, D. T. (2007). Statistical analyses and reproducible research. *Journal of Computational and Graphical Statistics*, 16(1), 1-23. doi.org/10.1198/106186007X178663.
- Gevrey, M., Dimopoulos, I. & Lek, S. (2003). Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological modelling*, 160(3), 249-264.
- Giasson, E., Figueiredo, S. R., Tornquist, C. G. & Clarke, R. T. (2008). Digital soil mapping using logistic regression on terrain parameters for several ecological regions in Southern Brazil. In *Digital soil mapping with limited data*, 225-232. Springer, Dordrecht. doi.org/10.1007/978-1-4020-8592-5_19.
- Gobin, A., Campling, P. & Feyen, J. (2001). Soil-landscape modelling to quantify spatial variability of soil texture. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26(1), 41-45. doi.org/10.1016/S1464-1909(01)85012-7.
- Gozukara, G., Zhang, Y. & Hartemink, A. E. (2021). Using vis-NIR and pXRF data to distinguish soil parent materials—An example using 136 pedons from Wisconsin, USA. *Geoderma*, 396, 115091. doi.org/10.1016/j.geoderma.2021.115091.

- Grinand, C., Arrouays, D., Laroche, B. & Martin, M. P. (2008). Extrapolating regional soil landscapes from an existing soil map: Sampling intensity, validation procedures, and integration of spatial context. *Geoderma*, 143(1-2), 180-190. doi.org/10.1016/j.geoderma.2007.11.004.
- Gruber, S. & Peckham, S. (2009). Land-surface parameters and objects in hydrology. *Developments in Soil Science*, 33, 171-194. doi:10.1016/S0166-2481(08)00007-X.
- Guo, Y., Shi, Z., Li, H. Y. & Triantafyllis, J. (2013). Application of digital soil mapping methods for identifying salinity management classes based on a study on coastal central China. *Soil Use and Management*, 29(3), 445-456. doi.org/10.1111/sum.12059.
- Harrell, F. (2001). *Regression Modeling Strategies: With Applications to Linear Models, Logistic Regression, and Survival Analysis*. Graduate Texts in Mathematics, Springer.
- Hartemink, A. E., McBratney, A. & Mendonça-Santos, M. L. (2008). *Digital soil mapping with limited data*. Springer, Heidelberg.
- Hartigan, J. A. & Wong, M. A. (1979). A K-means clustering algorithm. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 28(1), 100-108. doi.org/10.2307/2346830
- Hastie, T., Tibshirani, R. & Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer, New York, NY.
- Hengl, T. (2006). Finding the right pixel size. *Computers & geosciences*, 32(9), 1283-1298. doi.org/10.1016/j.cageo.2005.11.008.
- Hengl, T., Heuvelink, G. B., Kempen, B., Leenaars, J. G., Walsh, M. G., Shepherd, K. D., & Tondoh, J. E. (2015). Mapping soil properties of Africa at 250 m resolution: Random forests significantly improve current predictions. *PloS one*, 10(6), e0125814. doi.org/10.1371/journal.pone.0125814.
- Hengl, T. & Reuter, H. I. (2008). Geomorphometry: Concepts, Software, Applications. *Developments in Soil Science*, 33, Elsevier, 772 pp.
- Hengl, T., Toomanian, N., Reuter, H. I. & Malakouti, M. J. (2007). Methods to interpolate soil categorical variables from profile observations: lessons from Iran. *Geoderma*, 140(4), 417-427. doi.org/10.1016/j.geoderma.2007.04.022.
- Hengl, T. & Macmillan, R. A. (2019). *Predictive Soil Mapping with R*. Open Geo Hub foundation, Wageningen, the Netherlands.
- Heung, B., Bulmer, C. E. & Schmidt, M. G. (2014). Predictive soil parent material mapping at a regional-scale: a random forest approach. *Geoderma*, 214, 141-154. doi.org/10.1016/j.geoderma.2013.09.016.

- Heung, B., Ho, H. C., Zhang, J., Knudby, A., Bulmer, C. E. & Schmidt, M. G. (2016). An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. *Geoderma*, 265, 62-77. doi.org/10.1016/j.geoderma.2015.11.014.
- Heung, B., Hodúl, M. & Schmidt, M. G. (2017). Comparing the use of training data derived from legacy soil pits and soil survey polygons for mapping soil classes. *Geoderma*, 290, 51-68. doi.org/10.1016/j.geoderma.2016.12.001.
- Hijmans, R. J. (2020). raster: Geographic Data Analysis and Modeling. R package version 3, 4-5. <https://CRAN.R-project.org/package=raster>
- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G. & Jarvis, A. (2005). Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 25(15), 1965-1978. doi.org/10.1002/joc.1276.
- Hole, F. D. & Hironaka, M. (1960). An experiment in ordination of some soil profiles. *Soil Science Society of America Journal*, 24(4), 309-312. doi.org/10.2136/sssaj1960.03615995002400040028x.
- Hosmer, D. W. & Hjort, N. L. (2002). Goodness-of-fit processes for logistic regression: simulation results. *Statistics in Medicine*, 21(18), 2723-2738. doi: 10.1002/sim.1200.
- Hosmer, D. W. Lemeshow, S. & Sturdivant, R. X. (2013). *Applied Logistic Regression*, JohnWiley & Sons, Hoboken, NJ, USA.
- Houunkpatin, K. O., Schmidt, K., Stumpf, F., Forkuor, G., Behrens, T., Scholten, T. & Welp, G. (2018). Predicting reference soil groups using legacy data: A data pruning and Random Forest approach for tropical environment (Dano catchment, Burkina Faso). *Scientific reports*, 8(1), 1-16. doi.org/10.1038/s41598-018-28244-w.
- Howell, D., Kim, Y. & Haydu-Houdeshell, C. (2008). Development and Application of Digital Soil Mapping Within Traditional Soil Survey: What will it Grow Into? In *Hartemink A.E., McBratney A., Mendonça-Santos M. (eds) Digital Soil Mapping with Limited Data*. Springer, Dordrecht. doi.org/10.1007/978-1-4020-8592-5_4.
- Huang, J., Nhan, T., Wong, V. N., Johnston, S. G., Lark, R. M. & Triantafilis, J. (2014). Digital soil mapping of a coastal acid sulfate soil landscape. *Soil Research*, 52(4), 327-339. doi.org/10.1071/SR13314.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309. doi.org/10.1016/0034-4257(88)90106-X.
- Irish, R. R. (2000). *Landsat 7 science data users handbook*. Landsat 7 (L7) Data Users Handbook, LSDS-1927, Version 2.0, South Dakota, USA, June 2018. 42 p.

- Işık, E. I. & Usta, S. (2004) Ankara-Polatlı Sulu Tarım Arazilerinde Değişebilir Sodyum Yüzdesi, Sodyum Adsorbsiyon Oranı ve Gapon Katsayısı ilişkileri. *Tarım Bilimleri Dergisi*, 10(2), 174-181.
- Jacek, S. (1997). Landform characterization with geographic information systems. *Photogrammetric Engineering & Remote Sensing*, 63(2), 183-191.
- Jafari, A., Finke, P. A., Vande Wauw, J., Ayoubi, S. & Khademi, H. (2012). Spatial prediction of USDA-great soil groups in the arid Zarand region, Iran: comparing logistic regression approaches to predict diagnostic horizons and soil types. *European Journal of Soil Science*, 63(2), 284-298. doi.org/10.1111/j.1365-2389.2012.01425.x.
- Jafari, A., Khademi, H., Finke, P. A., Van de Wauw, J. & Ayoubi, S. (2014). Spatial prediction of soil great groups by boosted regression trees using a limited point dataset in an arid region, southeastern Iran. *Geoderma*, 232, 148-163. doi.org/10.1016/j.geoderma.2014.04.029.
- Jenny, H. (1941). *The factors of soil formation*. McGraw Hill, New York, NY. doi.org/10.1097/00010694-194111000-00009.
- Jensen, J. R. (2005). *Introductory digital image processing: A remote sensing perspective*, 3rd edition. Pearson Prentice Hall.
- Jeune, W., Francelino, M. R., Souza, E. D., Fernandes Filho, E. I. & Rocha, G. C. (2018). Multinomial logistic regression and random forest classifiers in digital mapping of soil classes in western Haiti. *Revista Brasileira de Ciência do Solo*, 42, e0170133. doi.org/10.1590/18069657rbcs20170133.
- Jiang, Z., Huete, A. R., Didan, K. & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote sensing of Environment*, 112(10), 3833-3845. doi.org/10.1016/j.rse.2008.06.006.
- Kacar, B. (2016). *Fiziksel ve Kimyasal Toprak Analizleri*. (610s). Ankara: Nobel Yayın Dağıtım.
- Kempen, B., Brus, D. J., Heuvelink, G. B. & Stoorvogel, J. J. (2009). Updating the 1: 50,000 Dutch soil map using legacy soil data: A multinomial logistic regression approach. *Geoderma*, 151(3-4), 311-326. doi.org/10.1016/j.geoderma.2009.04.023.
- Klingseisen, B., Metternicht, G. & Paulus, G. (2008). Geomorphometric landscape analysis using a semi-automated GIS-approach. *Environmental Modelling & Software*, 23(1), 109-121. doi.org/10.1016/j.envsoft.2007.05.007.
- Kovačević, M., Bajat, B. & Gajić, B. (2010). Soil type classification and estimation of soil properties using support vector machines. *Geoderma*, 154(3-4), 340-347. doi.org/10.1016/j.geoderma.2009.11.005.

- Kowalska, J. B., Zaleski, T., Józefowska, A. & Mazurek, R. (2019). Soil formation on calcium carbonate-rich parent material in the outer Carpathian Mountains—a case study. *Catena*, 174, 436-451. doi.org/10.1016/j.catena.2018.11.025.
- Kuhn, M., J. Wing, S., Weston, A., Williams, C., Keefer, A., Engelhardt, T., Cooper, Z., Mayer, B., Kenkel, T. R. C., Team, M., Benesty, R., Lescarbeau, A. & Scrucca, L. (2015). caret: Classification and regression training.
- Lagacherie, P. (2005). An algorithm for fuzzy pattern matching to allocate soil individuals to pre-existing soil classes. *Geoderma*, 128(3-4), 274-288. doi.org/10.1016/j.geoderma.2005.04.009.
- Lagacherie, P., McBratney A. B. & Voltz M. (2007). Digital soil mapping: An introductory perspective. *Developments in Soil Science*, 31, Elsevier, Amsterdam.
- Lagacherie, P., Snee, A. R., Gomez, C., Bacha, S., Coulouma, G., Hamrouni, M. H. & Mekki, I. (2013). Combining Vis–NIR hyperspectral imagery and legacy measured soil profiles to map subsurface soil properties in a Mediterranean area (Cap-Bon, Tunisia). *Geoderma*, 209, 168-176. doi.org/10.1016/j.geoderma.2013.06.005.
- Leenaars, J. G. B., Elias, E., Wösten, J. H. M., Ruiperez-González, M. & Kempen, B. (2020). Mapping the major soil-landscape resources of the Ethiopian Highlands using random forest. *Geoderma*, 361, 114067. doi.org/10.1016/j.geoderma.2019.114067.
- Leutner, B., Horning, D. & Schwalb-Willmann, J. (2019). RStoolbox: Tools for Remote Sensing Data Analysis. R package version 0.2.6. <https://CRAN.R-project.org/package=RStoolbox>
- Li, X., McCarty, G. W. Du, L. & Lee, S. (2020). Use of Topographic Models for Mapping Soil Properties and Processes. *Soil Systems*, 4, 32. doi:10.3390/soilsystems4020032.
- Ließ, M., Glaser, B. & Huwe, B. (2012). Uncertainty in the spatial prediction of soil texture: comparison of regression tree and Random Forest models. *Geoderma*, 170, 70-79. doi.org/10.1016/j.geoderma.2011.10.010.
- Lillesand, T. M., Kiefer, R. W. & Chipman, J. W. (2000). *Remote sensing and image interpretation*. John Wiley & Sons. New York.
- Liu, F., Geng, X., Fraser, W., Song, X. & Zhang, G. (2016). Soil polygon disaggregation through similarity-based prediction with legacy pedons. *Journal of Arid Land*, 8(5), 760-772. doi.org/10.1007/s40333-016-0087-7.
- Loiseau, T., Chen, S., Mulder, V. L., Dobarco, M. R., Richer-de-Forges, A. C., Lehmann, S. & Arrouays, D. (2019). Satellite data integration for soil clay content modelling at a national scale. *International Journal of Applied Earth*

- Ma, Y., Minasny, B., Malone, B. P. & Mcbratney, A. B. (2019). Pedology and digital soil mapping (DSM). *European Journal of Soil Science*, 70(2), 216-235. doi.org/10.1111/ejss.12790.
- MacMillan, R. A. (2008). Experiences with applied DSM: Protocol, availability, quality and capacity building. In *Digital Soil Mapping With Limited Data* (eds. A. E. Hartemink, A. B. McBratney & M. L. Mendonca-Santos), 113 – 136. Springer, Dordrecht, The Netherlands.
- MacMillan, R. A., Jones, R. K. & McNabb, D. H. (2004). Defining a hierarchy of spatial entities for environmental analysis and modeling using digital elevation models (DEMs). *Computers, Environment and Urban Systems*, 28(3), 175-200. doi.org/10.1016/S0198-9715(03)00019-X.
- MacQueen, J. B. (1967). *Some methods for classification and analysis of multivariate observations*. Proceedings of the Fifth Symposium on Math, Statistics, and Probability, University of California Press, Berkeley, CA.
- Maleki, S., Khormali, F., Mohammadi, J., Bogaert, P. & Bodaghabadi, M. B. (2020). Effect of the accuracy of topographic data on improving digital soil mapping predictions with limited soil data: An application to the Iranian loess plateau. *Catena*, 195, 104810. doi.org/10.1016/j.catena.2020.104810.
- Malone, B. (2018). ithir: Soil data and some useful associated functions. R package version 1.0
- Malone, B. P., Minasny, B. & McBratney, A. B. (2017) Categorical Soil Attribute Modeling and Mapping. In *Using R for Digital Soil Mapping*, 151-167. Springer.
- Marchetti, A., Piccini, C., Santucci, S., Chiuchiarelli, I. & Francaviglia, R. (2011). Simulation of soil types in Teramo province (Central Italy) with terrain parameters and remote sensing data. *Catena*, 85(3), 267-273. 10.1016/j.catena.2011.01.012
- Marques, M. A. & Mora, E. (1992). The influence of aspect on runoff and soil loss in a Mediterranean burnt forest (Spain). *Catena*, 19(3-4), 333-344. doi.org/10.1016/0341-8162(92)90007-X.
- Mattivi, P., Franci, F., Lambertini, A. & Bitelli, G. (2019). TWI computation: a comparison of different open source GISs. *Open Geospatial Data, Software and Standards*, 4(1), 1-12. doi.org/10.1186/s40965-019-0066-y.
- McBratney, A. B., Santos, M. M. & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52. doi.org/10.1016/S0016-7061(03)00223-4.

- McKenzie, N. J. & Austin, M. P. (1993). A quantitative Australian approach to medium and small scale surveys based on soil stratigraphy and environmental correlation. *Geoderma*, 57(4), 329-355. doi.org/10.1016/0016-7061(93)90049-Q.
- McKenzie, N. J. & Ryan, P. J. (1999). Spatial prediction of soil properties using environmental correlation. *Geoderma*, 89(1-2), 67-94. doi.org/10.1016/S0016-7061(98)00137-2.
- Metternicht, G. I. & Zinck, J. A. (2003). Remote sensing of soil salinity: potentials and constraints. *Remote sensing of Environment*, 85(1), 1-20. doi.org/10.1016/S0034-4257(02)00188-8.
- Michéli, E., Láng, V., Owens, P. R., McBratney, A. & Hempel, J. (2016). Testing the pedometric evaluation of taxonomic units on soil taxonomy-A step in advancing towards a universal soil classification system. *Geoderma*, 264, 340-349. doi.org/10.1016/j.geoderma.2015.09.008.
- Minai, J., Libohova, Z. & Schulze, D. G. (2020). Disaggregation of the 1: 100,000 Reconnaissance soil map of the Busia Area, Kenya using a soil landscape rule-based approach. *Catena*, 195, 104806. doi.org/10.1016/j.catena.2020.104806.
- Minasny, B., Malone, B. P. & McBratney, A. B. (Eds.). (2012). *Digital Soil Assessments and Beyond: Proceedings of the 5th Global Workshop on Digital Soil Mapping 2012*, CRC press, Sydney, Australia.
- Minasny, B., McBratney, A. B. & Hartemink, A. E. (2010). Global pedodiversity, taxonomic distance, and the World Reference Base. *Geoderma*, 155(3-4), 132-139. doi.org/10.1016/j.geoderma.2009.04.024.
- Mirakzehi, K., Pahlavan-Rad, M. R., Shahriari, A. & Bameri, A. (2018). Digital soil mapping of deltaic soils: A case of study from Hirmand (Helmand) river delta. *Geoderma*, 313, 233-240. doi.org/10.1016/j.geoderma.2017.10.048.
- Moore, I. D., Gessler, P. E., Nielsen, G. A. & Peterson, G. A. (1993). Soil attributes prediction using terrain analysis. *Soil Science Society of America Journal*, 57, 443-452. doi.org/10.2136/sssaj1993.03615995005700020026x.
- Moore, I. D., Grayson, R. B. & Ladson, A.R. (1991). Digital terrain modelling: A review of hydrological, geomorphological, and biological applications. *Hydrological Processes*, 5(1), 3-30. doi.org/10.1002/hyp.3360050103.
- Moran, C. J. & Bui, E. N. (2002). Spatial data mining for enhanced soil map modelling. *International Journal of Geographical Information Science*, 16(6), 533-549. doi.org/10.1080/13658810210138715.
- Mosleh, Z., Salehi, M. H., Jafari, A., Borujeni, I. E. & Mehnatkesh, A. (2017). Identifying sources of soil classes variations with digital soil mapping approaches in the Shahrekord plain, Iran. *Environmental earth sciences*, 76(21), 1-10. doi.org/10.1007/s12665-017-7100-0.

- Mosleh, Z., Salehi, M. H., Jafari, A., Borujeni, I. E. & Mehnatkesh, A. (2016). The effectiveness of digital soil mapping to predict soil properties over low-relief areas. *Environmental monitoring and assessment*, 188(3), 195. doi: 10.1007/s10661-016-5204-8.
- Moura-Bueno, J. M., Dalmolin, R. S. D., Horst-Heinen, T. Z., Cancian, L. C., Schenato, R. B., Dotto, A. C. & Flores, C. A. (2019). Prediction of soil classes in a complex landscape in Southern Brazil. *Pesquisa Agropecuária Brasileira*, 54, 1-13. doi.org/10.1590/S1678-3921.pab2019.v54.00420.
- MTA, (2021). Maden Tetkik ve Arama Genel Müdürlüğü Yerbilimleri Harita Görüntüleyici ve Çizim Editörü. (<http://yerbilimleri.mta.gov.tr/anasayfa.aspx>) (Son erişim tarihi: 10.04.2021)
- Mulder, V. L., De Bruin, S., Schaepman, M. E. & Mayr, T. R. (2011b). The use of remote sensing in soil and terrain mapping- A review. *Geoderma*, 162(1-2), 1-19. doi.org/10.1016/j.geoderma.2010.12.018.
- Mulder, V. L., Bruin, S.de. & Schaepman, M. E. (2011a). *The use of remote sensing for soil mapping at regional scale*. Wageningen Soil Meeting, September 18-22, Wageningen. 433880.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press. London, England.
- NASA, (2019). National Aeronautics and Space Administration - Aster Global Digital Elevation Model (Aster GDEM) NASA Official. (<http://www.gdem.aster.ersdac.or.jp>) (Son erişim tarihi: 02.06.2020)
- Nath, D. A. (2006). *Soil landscape modeling in the Northwest Iowa Plains region of O'Brien County, Iowa*, (Master of Thesis, Iowa State University)
- Nauman, T. W. & Thompson, J. A. (2014). Semi-automated disaggregation of conventional soil maps using knowledge driven data mining and classification trees. *Geoderma*, (213), 385-399. doi.org/10.1016/j.geoderma.2013.08.02
- Ngunjiri, M. W., Libohova, Z., Minai, J. O., Serrem, C., Owens, P. R. & Schulze, D. G. (2019). Predicting soil types and soil properties with limited data in the Uasin Gishu Plateau, Kenya. *Geoderma Regional*, 16, e00210. doi.org/10.1016/j.geodrs.2019.e00210.
- Nield, S. J., Boettinger, J. L. & Ramsey, R. D. (2007). Digitally mapping gypsic and natric soil areas using Landsat ETM data. *Soil Science Society of America Journal*, 71(1), 245-252. doi.org/10.2136/sssaj2006-0049.
- Oakes, H. (1954). *Türkiye Toprakları*. Yüksek ziraat Müh. Birliği Yayınları, Ankara.
- Oku, E., Essoka, A. & Thomas, E. (2010). Variability in soil properties along an Udalf toposequence in the humid forest zone of Nigeria. *Agriculture and Natural Resources*, 44(4), 564-573.

- Osat, M., Heidari, A., Eghbal, M. K. & Mahmoodi, S. (2016). Impacts of topographic attributes on Soil Taxonomic Classes and weathering indices in a hilly landscape in Northern Iran. *Geoderma*, 281, 90-101. doi.org/10.1016/j.geoderma.2016.06.020.
- Özcan, H., Ekinci, H., Yüksel, O., Kavdir, Y. & Kaptan, H. (2004), *Dardanos Yerleşkesi Toprakları*. Çanakkale Onsekiz Mart Üniversitesi Yayınları, 39.
- Pahlavan-Rad, M. R., Dahmardeh, K., Hadizadeh, M., Keykha, G., Mohammadnia, N., Gangali, M. & Brungard, C. (2020). Prediction of soil water infiltration using multiple linear regression and random forest in a dry flood plain, eastern Iran. *Catena*, 194, 104715. doi.org/10.1016/j.catena.2020.104715.
- Pahlavan-Rad, M. R., Khormali, F., Toomanian, N., Brungard, C. W., Kiani, F., Komaki, C. B. & Bogaert, P. (2016). Legacy soil maps as a covariate in digital soil mapping: a case study from Northern Iran. *Geoderma*, 279, 141-148. doi:10.1016/j.geoderma.2016.05.014.
- Pahlavan-Rad, M. R., Toomanian, N., Khormali, F., Brungard, C. W., Komaki, C. B. & Bogaert, P. (2014). Updating soil survey maps using random forest and conditioned Latin hypercube sampling in the loess derived soils of northern Iran. *Geoderma*, 232, 97-106. doi.org/10.1016/j.geoderma.2014.04.036.
- Piccini, C., Marchetti, A., Riviaccio, R. & Napoli, R. (2019). Multinomial logistic regression with soil diagnostic features and land surface parameters for soil mapping of Latium (Central Italy). *Geoderma*, 352, 385-394. doi.org/10.1016/j.geoderma.2018.09.037.
- Poggio, L., Gimona, A. & Brewer, M. J. (2013). Regional scale mapping of soil properties and their uncertainty with a large number of satellite-derived covariates. *Geoderma*, 209, 1-14. doi.org/10.1016/j.geoderma.2013.05.029
- Poppiel, R. R., Demattê, J. A. M., Rosin, N. A., Campos, L. R., Tayebi, M., Bonfatti, B. R. & Rahmati, M. (2021). High resolution middle eastern soil attributes mapping via open data and cloud computing. *Geoderma*, 385, 114890. doi.org/10.1016/j.geoderma.2020.114890.
- Poppiel, R. R., Lacerda, M. P., Demattê, J. A., Oliveira Jr, M. P., Gallo, B. C. & Safanelli, J. L. (2019). Pedology and soil class mapping from proximal and remote sensed data. *Geoderma*, 348, 189-206. doi.org/10.1016/j.geoderma.2019.04.028.
- R Core Team, (2019). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>
- Rasaei, Z. & Bogaert, P. (2019). Bayesian data fusion for combining maps of predicted soil classes: A case study using legacy soil profiles and DEM covariates in Iran. *Catena*, 182, 104138. doi.org/10.1016/j.catena.2019.104138.

- Rasaei, Z., Rossiter, D. G. & Farshad, A. (2020). Rescue and renewal of legacy soil resource inventories in Iran as an input to digital soil mapping. *Geoderma Regional*, 21, e00262. doi.org/10.1016/j.geodrs.2020.e00262.
- Regmi, N. R. & Rasmussen, C. (2018). Predictive mapping of soil-landscape relationships in the arid Southwest United States. *Catena*, 165, 473-486. doi.org/10.1016/j.catena.2018.02.031.
- Revelle, W. (2020). psych: Procedures for Personality and Psychological Research, Northwestern University, Evanston, Illinois, USA, <https://CRAN.R-project.org/package=psych> Version = 2.0.12.
- Roecker, S., Howell, D., Haydu-Houdeshell, C. & Blinn, C. (2010). A Qualitative Comparison of Conventional Soil Survey and Digital Soil Mapping Approaches. In *Digital Soil Mapping. Progress in Soil Science 2* (eds. Boettinger J.L., Howell D.W., Moore A.C., Hartemink A.E., Kienast-Brown S.), 369– 384. Springer, Dordrecht. doi.org/10.1007/978-90-481-8863-5_29.
- Rossel, R. V., Chen, C., Grundy, M. J., Searle, R., Clifford, D. & Campbell, P. H. (2015). The Australian three-dimensional soil grid: Australia's contribution to the GlobalSoilMap project. *Soil Research*, 53(8), 845-864. doi.org/10.1071/SR14366.
- Rossiter, D. G., Zeng, R. & Zhang, G. L. (2017). Accounting for taxonomic distance in accuracy assessment of soil class predictions. *Geoderma*, 292, 118-127. doi.org/10.1016/j.geoderma.2017.01.012.
- RStudio Team, (2020). RStudio: Integrated Development for R. RStudio, Inc., Boston, MA URL <http://www.rstudio.com/>.
- Safanelli, J. L., Chabrilat, S., Ben-Dor, E., & Dematté, J. A. M. (2020). Multispectral models from bare soil composites for mapping topsoil properties over Europe. *Remote Sensing*, 12(9), 1369. doi.org/10.3390/rs12091369.
- Sahragard, H. P. & Pahlavan-Rad, M. R. (2020). Prediction of Soil Properties Using Random Forest with Sparse Data in a Semi-Active Volcanic Mountain. *Eurasian Soil Science*, 53(9), 1222-1233. doi.org/10.1134/S1064229320090136.
- Samuel-Rosa, A., Heuvelink, G. B. M., Vasques, G. M. & Anjos, L. H. C. (2015). Do more detailed environmental covariates deliver more accurate soil maps? *Geoderma*, 243, 214-227. doi.org/10.1016/j.geoderma.2014.12.017.
- Sarabchi, A., Salehi, M. H., Delavar, M. A. & Naderi, M. (2008). *Assessing the capability of satellite data for soil mapping*. International Meeting on Soil Fertility Land Management and Agroclimatology. October 29-31, Turkey, 297-305.

- Sarı, M. (1987). *Landsat-4 Uydusu Sayısal Verileri Yardımıyla Detaylı Temel Toprak Haritalarının Oluşturulması Üzerine Araştırmalar*. (Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü)
- Sarkar, P. K., Bidwell, O. W. & Marcus, L. F. (1966). Selection of characteristics for numerical classification of soils. *Soil Science Society of America Journal*, 30(2), 269-272. doi.org/10.2136/sssaj1966.03615995003000020035x.
- Saunders, A. M. & Boettinger, J. L. (2006). Incorporating classification trees into a pedogenic understanding raster classification methodology, Green River Basin, Wyoming, USA. *Developments in Soil Science*, 31, 389-620. doi.org/10.1016/S0166-2481(06)31028-8.
- Schaetzl, R. J. & Anderson, S. (2005). *Soils: Genesis and Geomorphology*. Cambridge University Press. New York.
- Schmidt, K., Behrens, T., Friedrich, K. & Scholten, T. (2010). A method to generate soils from soil maps. *Journal of Plant Nutrition and Soil Science*, 173(2), 163-172. doi.org/10.1002/jpln.200800208.
- Scull, P., Franklin, J. & Chadwick, O. A. (2005). The application of classification tree analysis to soil type prediction in a desert landscape. *Ecological modelling*, 181(1), 1-15. doi.org/10.1016/j.ecolmodel.2004.06.036.
- Sharififar, A., Sarmadian, F., Malone, B. P. & Minasny, B. (2019). Addressing the issue of digital mapping of soil classes with imbalanced class observations. *Geoderma*, 350, 84-92. doi.org/10.1016/j.geoderma.2019.05.016.
- Shukla, G., Garg, R. D., Srivastava, H. S. & Garg, P. D. (2018). An effective implementation and assessment of a random forest classifier as a soil spatial predictive model. *International Journal of Remote Sensing*, 39(8), 2637-2669. doi.org/10.1080/01431161.2018.1430399.
- Shukla, M. K., Lal, R. & Ebinger, M. (2006). Determining soil quality indicators by factor analysis. *Soil and Tillage Research*, 87(2), 194-204. doi.org/10.1016/j.still.2005.03.011.
- Silva, B. P. C., Silva, M. L. N., Avalos, F. A. P., de Menezes, M. D. & Curi, N. (2019). Digital soil mapping including additional point sampling in Posses ecosystem services pilot watershed, southeastern Brazil. *Scientific reports*, 9(1), 1-12. doi.org/10.1038/s41598-019-50376-w.
- Soil Survey Division Staff, (2017). *Soil survey manual*. C. Ditzler, K. Scheffe, and H.C. Monger (eds.). USDA Handbook 18. Government Printing Office, Washington, D.C.
- Solmaz, M. A. (2010). *Eğimli Arazilerin Detaylı Toprak Etüd ve Haritalanması İçin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Teknolojilerini Kullanarak Yeni Yöntemlerin Geliştirilmesi*. (Doktora Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü)

- Sönmez, B., Özbahçe, A., Keçeci, M., Akgül, S., Aksoy, E., Madenoğlu, S. & Vargas, R. (2017). *Turkey's national geospatial soil organic carbon information system*. In Global Symposium on Soil Organic Carbon. March 21-23, Rome, 121-125.
- SPSS 23, (2015). IBM SPSS Statistics for Windows, Version 23.0. Armonk: IBM Corp.
- Stum, A. K., Boettinger, J. L., White, M. A. & Ramsey, R. D. (2010). Random forests applied as a soil spatial predictive model in arid Utah. In *Digital soil mapping* 179-190. Springer, Dordrecht. doi.org/10.1007/978-90-481-8863-5_15.
- Subburayalu, S. K. & Slater, B. K. (2013). Soil series mapping by knowledge discovery from an Ohio county soil map. *Soil Science Society of America Journal*, 77(4), 1254-1268. doi.org/10.2136/sssaj2012.0321.
- Sumfleth, K. & Duttman, R. (2008). Prediction of soil property distribution in paddy soil landscapes using terrain data and satellite information as indicators. *Ecological indicators*, 8(5), 485-501. doi.org/10.1016/j.ecolind.2007.05.005.
- Sun, X. L., Zhao, Y. G., Zhang, G. L., Wu, S. C., Man, Y. B. & Wong, M. H. (2011). Application of a Digital Soil Mapping Method in Producing Soil Orders on Mountain Areas of Hong Kong Based on Legacy Soil Data. *Pedosphere*, 21(3), 339-350. doi.org/10.1016/S1002-0160(11)60134-3.
- Taghizadeh-Mehrjardi, R., Minasny, B., Toomanian, N., Zeraatpisheh, M., Amirian-Chakan, A. & Triantafilis, J. (2019). Digital mapping of soil classes using ensemble of models in Isfahan region, Iran. *Soil Systems*, 3(2), 37. doi.org/10.3390/soilsystems3020037.
- Taghizadeh-Mehrjardi, R., Nabiollahi, K., Minasny, B. & Triantafilis, J. (2015). Comparing data mining classifiers to predict spatial distribution of USDA-family soil groups in Baneh region, Iran. *Geoderma*, 253, 67-77. doi.org/10.1016/j.geoderma.2015.04.008.
- Tağıl, Ş. & Jenness, J. (2008). GIS-based automated landform classification and topographic, landcover and geologic attributes of landforms around the Yazoren Polje, Turkey. *Journal of Applied Sciences*, 8(6), 910-921.
- Tobler, W. R. (1970). A computer movie simulating urban growth in the Detroit region. *Economic geography*, 46(1), 234-240.
- Tou, J. T. & Gonzalez, R. C. (1974). *Pattern recognition principles*. Addison-Wesley.
- Triantafilis, J., Kerridge, B. & Buchanan, S. M. (2009). Digital soil-class mapping from proximal and remotely sensed data at the field level. *Agronomy Journal*, 101(4), 841-853. doi.org/10.2134/agronj2008.0112.

- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150. doi.org/10.1016/0034-4257(79)90013-0.
- TÜBİTAK BİLGEM YTE, (2018). Toprak Organik Karbonu Projesi, Toprak Organik Karbonu Miktarı Tahminleme Modeli Raporu Proje Kodu: 100311, Revizyon No: 1.0.40. 39s.
- USDA-NRCS, (1999). Soil taxonomy: A basic system of soil classification for making and interpreting soil surveys. *Agriculture Handbook Number 436*.
- USGS, (2019). U.S Department of the Interior, Geological Survey- EarthExplorer. <http://earthexplorer.usgs.gov>. (Son erişim tarihi: Ekim-2019)
- Van Wambeke, A R. (2000). The Newhall simulation model for estimating soil moisture and temperature regimes. *Department of Crop and Soil Sciences*. Cornell University, Ithaca, NY. USA.
- van Zijl, G., van Tol, J., Tinnefeld, M. & Le Roux, P. (2019). A hillslope based digital soil mapping approach, for hydropedological assessments. *Geoderma*, 354, 113888. doi.org/10.1016/j.geoderma.2019.113888.
- Vargas, R. R. & Alim, M. (2007). Soil survey of a Selected Study Area in Somaliland. FAO- SWALIM. Project Report L-05. Nairobi, Kenya.
- Vasques, G. M., Demattê, J. A. M., Rossel, R. A. V., Ramírez-López, L. & Terra, F. S. (2014). Soil classification using visible/near-infrared diffuse reflectance spectra from multiple depths. *Geoderma*, 223, 73-78. doi.org/10.1016/j.geoderma.2014.01.019.
- Vaudour, E., Gomez, C., Fouad, Y. & Lagacherie, P. (2019). Sentinel-2 image capacities to predict common topsoil properties of temperate and Mediterranean agroecosystems. *Remote Sensing of Environment*, 223, 21-33. doi.org/10.1016/j.rse.2019.01.006.
- Vaysse, K. & Lagacherie, P. (2015). Evaluating digital soil mapping approaches for mapping GlobalSoilMap soil properties from legacy data in Languedoc-Roussillon (France). *Geoderma Regional*, 4, 20-30. doi.org/10.1016/j.geodrs.2014.11.003.
- Venables, W. N. & Ripley, B. D. (2002) *Modern Applied Statistics with S*. Springer, New York.
- Wadoux, A-C. & McBratney, A. B. (2021). Hypotheses, machine learning and soil mapping. *Geoderma*, 383, e114725. doi.org/10.1016/j.geoderma.2020.114725.
- Wadoux, A-C., Minasny, B. & McBratney, A. B. (2020). Machine learning for digital soil mapping: Applications, challenges and suggested solutions. *Earth-Science Reviews*, 210, e103359. doi.org/10.1016/j.earscirev.2020.103359.

- Wadoux, A-C., Samuel Rosa, A., Poggio, L. & Mulder, V. L. (2020). A note on knowledge discovery and machine learning in digital soil mapping. *European Journal of Soil Science*, 71, 133–136. doi.org/10.1111/ejss.12909.
- Walkley, A. & Black, I. A. (1934). An examination of degtjareff method for determining soil organic matter and a proposed modification of chromic acid in soil analysis. *Soil Science Society of America Journal*, 79(1), 459–465. doi.org/10.1097/00010694-193401000-00003.
- Webster, R. (2001). Statistics to support soil research and their presentation. *European Journal of Soil Science*, 52(2), 331-340. doi.org/10.1046/j.1365-2389.2001.00383.x.
- Wei, T. & Simko, V. (2017). R package "corrplot": Visualization of a Correlation Matrix (Version 0.84).
- Weismiller, R. A., Persinger, I. D. & Montgomery, O. L. (1977). Soil inventory from digital analysis of satellite scanner and topographic data. *Soil Science Society of America Journal*, 41(6), 1166-1170. doi.org/10.2136/sssaj1977.03615995004100060031x.
- White, R. E. (2013). *Principles and practice of soil science: the soil as a natural resource*. Wiley-Blackwell.
- Wiesmeier, M., Barthold, F., Blank, B. & Kögel-Knabner, I. (2011). Digital mapping of soil organic matter stocks using Random Forest modeling in a semi-arid steppe ecosystem. *Plant and soil*, 340(1), 7-24. doi.org/10.1007/s11104-010-0425-z.
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E. & Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote sensing of environment*, 225, 127-147. doi.org/10.1016/j.rse.2019.02.015.
- Xiao, J., Shen, Y., Tateishi, R. & Bayaer, W. (2006). Development of topsoil grain size index for monitoring desertification in arid land using remote sensing. *International Journal of Remote Sensing*, 27(12), 2411-2422. doi.org/10.1080/01431160600554363.
- Yang, R., Rossiter, D. G., Liu, F., Lu, Y., Yang, F., Yang, F. & Zhang, G. (2015). Predictive mapping of topsoil organic carbon in an alpine environment aided by Landsat TM. *PLoS One*, 10(10), e0139042. doi.org/10.1371/journal.pone.0139042.
- Zare, E., Ahmed, M. F., Malik, R. S., Subasinghe, R., Huang, J. & Triantafilis, J. (2017). Comparing traditional and digital soil mapping at a district scale using residual maximum likelihood analysis. *Soil Research*, 56(5), 535-547. doi.org/10.1071/SR17220.

- Zare, E., Huang, J. & Triantafilis, J. (2016). Identifying soil landscape units at the district scale by numerically clustering remote and proximal sensed data. *Computers and Electronics in Agriculture*, 127, 510-520. doi.org/10.1016/j.compag.2016.07.001.
- Zeraatpisheh, M., Ayoubi, S., Brungard, C. W. & Finke, P. (2019). Disaggregating and updating a legacy soil map using DSMART, fuzzy c-means and k-means clustering algorithms in Central Iran. *Geoderma*, 340, 249-258. doi.org/10.1016/j.geoderma.2019.01.005.
- Zeraatpisheh, M., Ayoubi, S., Jafari, A. & Finke, P. (2017). Comparing the efficiency of digital and conventional soil mapping to predict soil types in a semi-arid region in Iran. *Geomorphology*, 285, 186-204. doi.org/10.1016/j.geomorph.2017.02.015.
- Zeraatpisheh, M., Ayoubi, S., Jafari, A., Tajik, S. & Finke, P. (2019). Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma*, 338, 445-452. doi.org/10.1016/j.geoderma.2018.09.006.
- Zeraatpisheh, M., Ayoubi, S., Sulieman, M. & Rodrigo-Comino, J. (2019). Determining the spatial distribution of soil properties using the environmental covariates and multivariate statistical analysis: a case study in semi-arid regions of Iran. *Journal of Arid Land*, 11(4), 551-566. doi.org/10.1007/s40333-019-0059-9.
- Zevenbergen, L. W. & Thorne, C. R. (1987). Quantitative analysis of land surface topography. *Earth surface processes and landforms*, 12(1), 47-56. doi.org/10.1002/esp.3290120107.
- Zhu, A. X., Hudson, B., Burt, J., Lubich, K. & Simonson, D. (2001). Soil mapping using GIS, expert knowledge, and fuzzy logic. *Soil Science Society of America Journal*, 65(5), 1463-1472. doi.org/10.2136/sssaj2001.6551463x.
- Zhu, A. X., Lu, G., Liu, J., Qin, C. Z. & Zhou, C. (2018). Spatial prediction based on Third Law of Geography. *Annals of GIS*, 24(4), 225-240. doi.org/10.1080/19475683.2018.1534890.

EKLER

EK A. Toprak örnekleri analiz sonuçları

EK B. Laboratuvar analizleri görselleri



EK A. Toprak örnekleri analiz sonuçları

Çizelge A.1. Toprak örnekleri analiz sonuçları

Örnek no	Seri	X	Y	Kil(%)	Silt(%)	Kum(%)	pH	EC(mS cm-1)	Org.Mad. (%)	CaCO ₃ Eşd.(%)	KDK(cmol kg-1)	Değiş.Na (cmol kg-1)	Değiş. Na (%)
1	Pazararkası	288475.31	4202275.73	42.53	29.99	27.49	6.34	0.4	1.15	0.59	18.09	0.1	0.54
2	ÇAT	290729.19	4202032.67	45.94	15.91	38.15	7.21	0.56	1.38	0.43	21.35	0.09	0.44
3	ÇAT	290910.41	4201780.07	48.52	20.37	31.11	6.93	0.71	3.13	0.26	25.32	0.1	0.39
4	Pazararkası	290963.16	4201837.91	38.54	17.59	43.87	6.65	0.57	2.33	0.34	19.71	0.09	0.47
5	Pazararkası	291338.29	4202350.25	46.17	12.47	41.36	7.07	0.58	1.42	1.03	22.6	0.11	0.5
6	Pazararkası	291930.81	4202771.91	41.01	24.72	34.27	7.74	0.74	1.38	13.88	24.52	0.09	0.36
7	Pazararkası	291559.24	4202738.84	36.75	30.17	33.08	7.75	0.77	1.39	3.35	26.06	0.09	0.35
8	Pazararkası	291375.19	4203052.57	29.27	23.95	46.78	7.65	0.49	4.74	12.6	20.03	0.08	0.41
9	Pazararkası	291899.25	4202395.16	50.21	22.32	27.47	7.76	0.84	1.03	5.04	27.81	0.14	0.52
10	Onaç	291850.75	4200082.97	34.16	20.6	45.24	7.82	0.43	0.93	1.35	18.95	0.08	0.45
11	Onaç	291681.41	4199881.84	47.53	22.07	30.4	7.59	0.39	1.77	0.86	20.76	0.09	0.44
12	Yenibağlar	291154.58	4199974.88	52.97	30.16	16.88	7.76	0.66	1.31	1.41	27.5	0.12	0.45
13	Yenibağlar	290917.57	4199477.44	29	20.62	50.37	7.78	0.63	0.91	4.89	19.94	0.1	0.49
14	Yenibağlar	290695.73	4200149.39	23.7	21.56	54.73	7.52	0.5	0.96	0.84	16.94	0.09	0.53
15	Yenibağlar	290314.7	4200325.71	23.37	23.3	53.33	7.36	0.68	0.76	0.41	14.43	0.1	0.68
16	Yenibağlar	289596.25	4200723.59	34.74	18.84	46.42	7	0.77	0.97	0.86	22.84	0.11	0.48
17	İslamköy	291346.47	4200832.37	33.73	16.76	49.51	7.38	0.47	1.81	0.43	22.01	0.09	0.41
18	İslamköy	292936.29	4199644.58	28.8	32.85	38.36	7.44	0.62	2	24.88	11.62	0.09	0.76
19	İslamköy	294458.77	4201192.27	45.59	18.33	36.08	8.01	0.6	1.67	8.69	29.09	0.27	0.93

Çizelge A.1. Toprak örnekleri analiz sonuçları (Devam)

Örnek no	Seri	X	Y	Kil(%)	Silt(%)	Kum(%)	pH	EC(mS cm-1)	Org.Mad. (%)	CaCO ₃ Eşd.(%)	KDK(cmol kg-1)	Değiş.Na (cmol kg-1)	Değiş. Na (%)
20	İslamköy	293600.75	4201809.83	47.46	25.2	27.34	7.43	1.69	6.04	12.92	21.22	1.76	8.3
21	İslamköy	292751.7	4197159.96	26.79	26.72	46.49	7.46	1.24	1.04	11.45	14.15	0.15	1.04
22	İslamköy	293344.82	4197591.05	33.63	51.94	14.42	7.76	0.57	1.77	33.14	15.9	0.12	0.74
23	İslamköy	294155.11	4199258.52	35.99	40.16	23.85	8.01	0.35	2.12	23.09	17.25	0.14	0.8
24	İslamköy	294915.31	4199520.72	31.19	42.58	26.23	7.83	0.54	1.68	28.55	14.44	0.08	0.54
25	İslamköy	292400.91	4197494.65	41.93	32.41	25.66	7.94	0.56	1.83	15.24	20.76	0.11	0.54
26	İslamköy	292540.74	4196528.68	32.81	32.73	34.46	7.71	0.84	1.73	13.23	18.47	0.15	0.81
27	İslamköy	294607.5	4198120.08	36.63	38.65	24.72	7.88	0.73	1.55	20.35	19.28	0.41	2.12
28	İslamköy	295426.37	4196972.51	31.42	24	44.58	7.76	0.57	2.28	11.98	21.35	0.14	0.65
29	Akçay	293491.15	4202286.42	26.27	37.34	36.38	7.81	0.36	2.3	27.26	11.95	0.16	1.32
30	Akçay	292923.3	4200522.16	40.59	49.08	10.33	7.78	0.58	3.04	30.01	21.86	0.12	0.54
31	Bayat	292994.7	4201377.29	42.05	33.55	24.4	8	0.58	2.14	11.5	22.1	0.16	0.73
32	Bayat	291644.8	4197750.69	43.52	32.91	23.57	7.79	0.67	2.21	16.56	22.1	0.14	0.61
33	Bayat	292498.3	4196242.93	41.84	26.8	31.36	7.67	0.96	2.07	13.05	24.12	0.88	3.64
34	Bayat	294878.96	4197306.33	63.73	21.85	14.42	8	0.87	2.05	6.93	35.28	0.34	0.95
35	Kuleönü	294312.78	4195901.06	64.81	26.9	8.29	7.88	0.68	2.41	5.49	40.11	0.26	0.65
36	Kuleönü	291232.68	4195214.57	73.76	19.67	6.57	7.84	1.17	2.27	5.95	40.24	0.13	0.31
37	Orkav	292062.71	4195147.18	60.76	26.05	13.18	8.02	0.62	1.87	8.82	31.8	0.12	0.39
38	Orkav	293422.1	4195618.79	70.06	23.59	6.35	7.89	0.78	2.29	23.84	28.69	0.2	0.69
39	Orkav	293248.21	4195652.94	62.84	15.28	21.89	7.96	0.62	2.33	1.81	30.94	0.12	0.39
40	Orkav	293329.46	4195002.23	57.55	22.27	20.17	7.92	0.79	1.97	2.8	29.97	0.16	0.54

Çizelge A.1. Toprak örnekleri analiz sonuçları (Devam)

Örnek no	Seri	X	Y	Kil(%)	Silt(%)	Kum(%)	pH	EC(mS cm-1)	Org.Mad. (%)	CaCO ₃ Eşd.(%)	KDK(cmol kg-1)	Değiş.Na (cmol kg- 1)	Değiş. Na (%)
41	Orkav	295963.68	4195580.32	69.08	21.45	9.46	7.96	0.95	1.79	7.43	36.48	0.28	0.76
42	Orkav	295015.16	4196186.95	62.56	24.7	12.73	8.07	0.72	2.09	7.6	33.4	0.23	0.7
43	Serenli	292825.37	4194269.18	63.72	24.48	11.8	7.03	0.81	2.69	0.55	30.22	0.13	0.44
44	Serenli	294204.75	4194106.77	54.08	30.23	15.69	7.07	0.63	1.96	0.35	25.66	0.13	0.49
45	Serenli	292971.27	4193482.64	27.56	20.42	52.03	7.41	0.46	2.97	0.34	15.43	0.11	0.71
46	Serenli	294916.34	4193113.56	23.34	18.28	58.38	7.03	0.49	4.45	0.5	12.32	0.11	0.93
47	Serenli	293576	4192906.64	32.4	19.97	47.63	7.7	0.33	2.29	0.34	20.8	0.16	0.77
48	Serenli	295609.45	4194312.17	25.46	27.84	46.7	7.25	2.07	6.11	1.05	21.77	0.4	1.83
49	Serenli	294476.93	4192163.87	25.88	20.88	53.24	7.32	0.35	1.74	0.68	17.47	0.17	1
50	Serenli	295347.15	4191735.22	22.38	20.55	57.07	6.55	0.23	1.52	0.34	12.04	0.14	1.13
51	Kustepe	296103.37	4194296.21	24.14	18.26	57.6	7.65	0.51	1.95	0.66	16.75	0.13	0.77
52	Büyükgökç eli	298517.93	4193873.8	25.44	16.4	58.15	7.86	0.42	2.24	1.68	17.12	0.12	0.7
53	Büyükgökç eli	298543.45	4193658.53	26.75	19.7	53.56	7.87	0.36	2.4	5.42	16.63	0.11	0.67
54	Büyükgökç eli	298619.7	4194670.78	28.6	19.54	51.87	7.86	0.53	2.71	1.34	20.99	0.13	0.64
55	Büyükgökç eli	299393.18	4195290.29	26.75	23.86	49.39	7.75	0.44	2.86	9.32	16.72	0.17	1.04
56	Büyükgökç eli	299671.88	4194630.24	33.36	28.33	38.31	7.76	0.54	3.16	11.3	23	0.13	0.56
57	Çayakıntısı	300109	4196675.66	37.57	26.23	36.2	7.88	0.69	2.63	12.16	22.29	0.15	0.67
58	Dikilitaş	296260.34	4198012.19	54.72	20.84	24.44	7.76	0.88	3.59	1.97	35.74	0.31	0.87
59	Dikilitaş	295876.14	4200190.73	48.68	21.7	29.63	7.89	0.95	2.51	8.15	33.4	0.41	1.23
60	Dikilitaş	295544.03	4199158.99	44.26	24.33	31.41	7.9	0.72	2.04	7.6	29.38	0.27	0.92


Çizelge A.1. Toprak örnekleri analiz sonuçları (Devam)

Örnek no	Seri	X	Y	Kil(%)	Silt(%)	Kum(%)	pH	EC(mS cm-1)	Org.Mad. (%)	CaCO ₃ Eşd.(%)	KDK(cmol kg-1)	Değiş.Na (cmol kg-1)	Değiş. Na (%)
61	Dikilitaş	296025.54	4198419.67	52.77	18.73	28.5	7.8	0.98	2.69	3.41	34.77	0.19	0.55
62	Karaağaç	294960.51	4202438.25	48.63	35.47	15.91	7.91	0.66	3.32	23.28	36.47	0.21	0.58
63	Karaağaç	295040.7	4201893.9	49.27	36.51	14.22	7.82	0.88	3.01	13.88	37.94	0.27	0.72
64	Karaağaç	295540.63	4200724.78	48.41	24.32	27.26	7.88	0.82	2.39	12.3	34.79	0.17	0.48
65	Yeşilova	301503.31	4196883.62	21.55	21.63	56.82	7.93	0.15	2.16	9.96	14.91	0.12	0.77
66	Kırlar	301820.09	4196902.38	31.55	21.14	47.31	7.86	0.34	2.68	33.88	18.33	0.14	0.79
67	Kırlar	302017.9	4196775.46	25.82	27.95	46.24	7.91	0.35	3.29	15.87	19.26	0.12	0.64
68	Kırlar	302098.16	4196819.83	25.33	35.93	38.73	7.85	0.37	5.66	21.69	22.11	0.12	0.52
69	Kırlar	302464.33	4195584.05	29.07	24.85	46.08	7.79	0.63	2.89	11.68	21.61	0.13	0.58
70	Hıdırlık	293923.71	4202586.44	32.21	23.72	44.07	7.97	0.5	3.08	11.99	23.89	0.12	0.5
71	Hıdırlık	294444.27	4202421.55	30.14	23.99	45.87	7.96	0.42	2.06	13.79	22.47	0.15	0.68
72	Karaağaç	297202.21	4199869.08	29.43	24.26	46.31	7.84	0.59	2.01	8	23.74	0.12	0.49
73	Pembeli	298898.86	4198457.79	25.9	24.94	49.15	7.95	0.44	2.05	6.71	20.04	0.14	0.7
74	Pembeli	299087.92	4197198.41	26.22	29.43	44.35	7.76	0.62	2.48	13.91	24.27	0.13	0.54
75	Kırbağlar	299776.58	4198915.64	25.07	22.02	52.91	7.88	0.43	1.93	9.13	19.35	0.13	0.7
76	Pembeli	300572.25	4198898.01	13.28	17.42	69.3	8.04	0.11	1.89	8.9	9.34	0.11	1.15
77	Pembeli	299625.98	4199170.94	28.13	33.6	38.27	7.74	0.56	2.62	9.98	20.8	0.1	0.5
78	Pembeli	299414.63	4199222.42	25.1	28.3	46.6	7.77	0.48	1.87	18.61	20.3	0.13	0.63
79	Pembeli	299472.4	4199483.83	40.14	25.46	34.4	7.66	0.96	2.36	35.08	26.57	0.16	0.6
80	Pembeli	297952.74	4200224.4	30.47	30.55	38.97	7.83	0.75	2.57	17.44	25.83	0.14	0.53
81	Pembeli	297269.63	4200876.1	20.87	33.42	45.71	7.11	0.73	2.99	5.06	21.61	0.23	1.08

Çizelge A.1. Toprak örnekleri analiz sonuçları (Devam)

Örnek no	Seri	X	Y	Kil(%)	Silt(%)	Kum(%)	pH	EC(mS cm-1)	Org.Mad. (%)	CaCO ₃ Eşd.(%)	KDK(cmol kg-1)	Değiş.Na (cmol kg-1)	Değiş. Na (%)
82	Pembeli	297524.05	4201145.52	22.91	29.21	47.88	7.81	0.31	3.59	13.14	19.2	0.12	0.61
83	Pembeli	296608.51	4201640.14	32.58	36.99	30.42	7.83	0.4	5.34	20.75	23.81	0.13	0.54
84	Pembeli	296208.29	4202049.85	25.64	32.1	42.26	7.75	0.38	2.64	7.43	18.67	0.16	0.84
85	Yakabağlar	295447.25	4202266.83	30.94	29.92	39.14	7.93	0.53	2.05	23.25	26.22	0.12	0.47
86	Yakabağlar	295358.97	4202548.53	24.87	21.85	53.28	8.01	0.27	1.35	9.56	18.29	0.11	0.59
87	Yakabağlar	294780.38	4203025.74	21.42	24.7	53.88	7.91	0.29	1.84	8.14	20.28	0.13	0.62
88	Yakabağlar	294604.95	4203392.81	20.5	25.68	53.82	7.57	0.46	3.73	9.78	20.18	0.12	0.62
89	Yakabağlar	294074.18	4203498.77	23.89	21.77	54.34	7.6	0.51	1.13	1.49	18.92	0.11	0.56
90	Yakabağlar	294082.47	4203827.92	21.28	19.11	59.61	7.79	0.3	2.52	4.92	18.92	0.11	0.57
91	Yakabağlar	294127.51	4203930.5	20.19	23.32	56.49	7.87	0.27	3.66	4.47	17.96	0.11	0.61

EK B. Laboratuvar analizleri görselleri



Şekil B.1. Laboratuvar analizleri görselleri

ÖZGEÇMİŞ


Adı Soyadı :

Doğum Yeri ve Yılı :

Medeni Hali :

Yabancı Dili :

E-posta :



Eğitim Durumu

Lise :

Lisans :

Mesleki Deneyim

Yayınlar

