



**T.C.
HARRAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

DOKTORA TEZİ

**TOPRAK KALİTESİNİN YAPAY SİNİR AĞLARI İLE
DEĞERLENDİRİLMESİ BİNGÖL SOLHAN OVASI ÖRNEĞİ**

VEYSEL ALP

TOPRAK BİLİMİ VE BİTKİ BESLEME ANA BİLİMDALİ

**Şanlıurfa
2025**



**T.C.
HARRAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

DOKTORA TEZİ

**TOPRAK KALİTESİNİN YAPAY SİNİR AĞLARI İLE
DEĞERLENDİRİLMESİ BİNGÖL SOLHAN OVASI ÖRNEĞİ**

VEYSEL ALP

**TOPRAK BİLİMİ VE BİTKİ BESLEME ANA BİLİMDALİ
Tez Danışmanı: Prof. Dr. Salih AYDEMİR**

**Şanlıurfa
2025**

TEŐEKKÖR

Tez alıřmamda yardımlarını esirgemeyensayın Prof. Dr. Salih AYDEMİR'e ve alıřmalarımın her süreci desteklerini esirgemeyerek bana yardımcı olan hocalarım Prof. Dr. Ali Volkan BİLGİLİ, Prof. Dr. Ali Rıza DEMİRKIRAN, Do. Dr. Vedat BEYYAVAŐ, Do. Dr. Aziz KABA, Dr. Öğretim Üyesi Mira KILI, Makina Mühendisi Ferhat HAMİDİ ve Bilgisayar Mühendisi Bilal SÖNMEZ'e, ayrıca bana motivasyon kaynağı olan kıymetli ağabeyim Burak BIYIKI'ya teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
ŞEKİLLER DİZİNİ	iii
ÇİZELGELER DİZİNİ	iv
KISALTMALAR	v
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	6
2.1. Toprak Kalitesi ve Belirleyici Parametreler	6
2.2. Jeostatistiksel Yöntemlerle Toprak Özelliklerinin Haritalanması	10
2.3. Makine Öğrenmesi ile Toprak Özelliklerinin Modellenmesi	14
3. GEREÇ VE YÖNTEM	20
3.1. Araştırma Alanının Temel Özellikleri	20
3.2. Solhan Ovası'nın Ana Toprak Oluşturan Kayaçları	20
3.3. Çalışma Alanının Toprak Örtüsü ve Hidro-Pedolojik Özellikleri	21
3.4. Toprak Örneklemesi ve Analizleri	22
3.5. Çalışmada Kullanılan Yazılımlar, Veri İşleme ve Modellemesi	25
3.6. Ön Etüt ve Büro Çalışmaları	26
3.7. Arazi Çalışmaları	26
3.8. Laboratuvar Çalışmaları	27
3.9. Jeostatistiksel Yöntem	31
3.10. Yapay Sinir Ağları (YSA)	32
3.10.1. Levenberg–Marquardt (LM) Eğitim Algoritması	34
3.10.2. Ölçeklenmiş Eşlenik Gradyan (SCG) Algoritması	36
3.10.3. Bayesian Düzenlemesi (BR) Eğitim Algoritması	38
3.11. Toprak Kalite İndekslerinin (TKİ) Hesaplanması	39
4. BULGULAR	41
4.1. Solhan Ovası Topraklarının Değişkenleri Arasındaki Korelasyon	41
4.2. Fiziksel, Kimyasal ve Biyolojik Analizlerin değerlendirilmesi	44
4.2.1. Silindir Metodu İle Hacim Ağırlığı Tayini	44
4.2.2. Tekstür Analizi	45
4.2.3. Toprak Reaksiyonu (pH)	47
4.2.4. Elektriksel İletkenlik ($\mu\text{s/cm}$)	50
4.2.5. Organik Madde (%)	51
4.2.6. Kireç İçeriği (%)	53
4.2.7. Toprakta Değişebilir Katyon Analizi (me100gr-1)	54
4.2.8. KDK (Kasyon Değişim Kapasitesi) (me 100g-1)	56
4.2.9. Tarla Kapasitesi	58
4.2.10. Solma Noktası	59
4.2.11. Yarayışlı Su İçeriği	61
4.3. Solhan Ovası Arazilerin Tanımlayıcı İstatistikleri	62
4.4. Yapay Sinir Ağları ile Toprak Kalite Parametre Tahmini	63
4.4.1. Yapay Sinir Ağlarının Kullanımı	64
4.4.2. Yapay Sinir Ağları ile Değişebilir Katyon Yüzdesi tahmini	64
4.4.3. Yapay Sinir Ağları ile Katyon Değişim Kapasitesi Tahmin	66
4.4.4. Yapay Sinir Ağları ile Tarla Kapasitesi Tahmini	68
4.4.5. Yapay Sinir Ağları ile Solma Noktası Tahmini	70
5. TARTIŞMA	72
5.1. Toprak Kalitesinin Değerlendirilmesi	74
5.1.1. Toprak Fiziksel Göstergeleri	76
5.1.2. Toprak Kimyasal Göstergeleri	78
5.1.3. Toprak Biyolojik Göstergeleri	79
5.1.4. Genel Toprak Kalitesi	80

5.2. Yapay Sinir Ağları ile Toprak Özelliklerinin İstatistiksel Analiz Sonuçları	81
5.2.1. Yapay Sinir Ağları ile Değişebilir Katyon Yüzdesi Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları	81
5.2.2. Yapay Sinir Ağları ile Katyon Değişim Kapasitesi Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları	82
5.2.3. Yapay Sinir Ağları ile Tarla Kapasitesi Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları	82
5.2.4. Yapay Sinir Ağları ile Solma Noktası Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları	83
5.2.5. Yapay Sinir Ağı Modellemesi	83
5.2.6. Öğrenme Algoritmaları	84
5.2.7. Gizli Katman Sayısı ve Nöron Sayısı	84
5.2.8. Giriş Verilerinin Etkisi	85
5.2.9. Genel Değerlendirme	85
6. SONUÇLAR	86
7. ÖNERİLER	88
KAYNAKLAR	90
ÖZGEÇMİŞ	106

ÖZET

DOKTORA TEZİ

TOPRAK KALİTESİNİN YAPAY SINIR AĞLARI İLE DEĞERLENDİRİLMESİ BİNGÖL SOLHAN OVASI ÖRNEĞİ

VEYSEL ALP

HARRAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TOPRAK BİLİMİ VE BİTKİ BESLEME ANA BİLİMDALI

Tez Danışman: Prof. Dr. Salih AYDEMİR

Yıl: 2025, Sayfa : 106

Bu araştırmada, Bingöl Solhan Ovası'nda bazı toprak özelliklerinin modellenmesi amacıyla, ArcGIS 10.8 yazılımıyla 300 m x 300 m aralıklı gridler kullanılarak 85 noktadan 0-30 cm derinlikteki toprak örnekleri alınmış ve uzman görüşüyle belirlenen toprak kalite parametreleriyle ovanın genel toprak kalitesi modellenmiştir. Toprak numunelerinin fiziksel, kimyasal ve biyolojik analizleri yapılmış, her parametre normalize edilerek SMAF modeli ve eklemeli indeks yöntemiyle toprak kalite indeksi hesaplanmıştır. Sonuçlara göre; fiziksel kalite (ortalama 60 skor) "orta", kimyasal (54 skor) ve biyolojik (48 skor) kalite "düşük", genel toprak kalitesi ise (56 skor) "orta" olarak sınıflandırılmıştır. Toprakların işlevselliği için fiziksel, kimyasal ve biyolojik kalitenin iyileştirilmesi gereklidir. Bu da uygun arazi yönetimi ve amenajman sistemlerine bağlıdır. Kötü uygulamalar, zaten zayıf olan özellikleri daha da bozabilir. Çalışmada, SMAF modelinin toprak kalitesi değerlendirmede etkili bir araç olduğu ve çiftçiler/arazi yöneticileri için sürdürülebilir kararlar almayı kolaylaştırdığı belirlenmiştir. Araştırmanın ikinci aşamasında, toprak özellikleri yapay sinir ağları (YSA) ile tahmin edilmiştir. Levenberg-Marquardt (LM), Scaled Conjugate Gradient (SCG) ve Bayesian Düzenleme (BR) algoritmaları kullanılarak hiperparametreler optimize edilmiştir. %70 eğitim, %15 test ve %15 doğrulama verisiyle, 0-30 nöronlu çift gizli katmanlı ağ yapıları test edilmiştir. LM algoritması tüm tahminlerde en iyi performansı göstermiştir: Değişebilir katyon yüzdesi (%85 doğruluk, 1.705 MAE, 2.255 RMSE), katyon değişim kapasitesi (%73 doğruluk, 0.439 MAE, 0.533 RMSE), tarla kapasitesi (%97 doğruluk, 0.560 MAE, 1.012 RMSE) ve solma noktası (%99 doğruluk, 0.003 MAE, 0.004 RMSE). LM, tüm modellerde en yüksek R² ve en düşük hata değerlerini sağlamıştır. Böylece, maliyetli ve uzmanlık gerektiren toprak parametreleri yüksek doğrulukla tahmin edilebileceği kanıtlanmıştır.

ANAHTAR KELİMELELER: Toprak Kalitesi, ordinary kriging, Modelleme, SMAF, yapay sinir ağları, hiperparametre

ABSTRACT

DOCTORATE THESIS

EVALUATION OF SOIL QUALITY WITH ARTIFICIAL NEURAL NETWORKS THE CASE OF BİNGÖL SOLHAN PLAIN

VEYSEL ALP

**HARRAN UNIVERSITY
INSTITUTE OF GRADUATE EDUCATION
DEPARTMENT OF SOIL SCIENCE AND PLANT NUTRITION**

Thesis Supervisor: Prof. Dr. Salih AYDEMİR

Year: 2025, Page : 106

In this study, in order to model some soil properties in Bingöl Solhan Plain, soil samples at 0-30 cm depth were taken from 85 points using 300 m x 300 m spaced grids with ArcGIS 10.8 software and the general soil quality of the plain was modeled with soil quality parameters determined by expert opinion. Physical, chemical and biological analyses of soil samples were carried out and each parameter was normalized and soil quality index was calculated using SMAF model and additive index method. According to the results; physical quality (average score of 60) was classified as “medium”, chemical (score of 54) and biological (score of 48) quality as ‘low’ and overall soil quality (score of 56) as “medium”. Improvement of physical, chemical and biological quality is necessary for the functionality of soils. This depends on appropriate land management and management systems. Poor practices can further degrade already poor properties. The study found that the SMAF model is an effective tool for soil quality assessment and facilitates sustainable decision making for farmers/land managers. In the second stage of the research, soil properties were estimated by artificial neural networks (ANN). Levenberg-Marquardt (LM), Scaled Conjugate Gradient (SCG) and Bayesian Regularization (BR) algorithms were used to optimize the hyperparameters. Double hidden layer networks with 0-30 neurons were tested with 70% training, 15% testing and 15% validation data. The LM algorithm showed the best performance in all predictions: Percent exchangeable cation (85% accuracy, 1.705 MAE, 2.255 RMSE), cation exchange capacity (73% accuracy, 0.439 MAE, 0.533 RMSE), field capacity (97% accuracy, 0.560 MAE, 1.012 RMSE) and wilting point (99% accuracy, 0.003 MAE, 0.004 RMSE). LM provided the highest R^2 and lowest error values in all models. Thus, it was proved that costly and specialized soil parameters can be estimated with high accuracy.

KEYWORDS: Soil Quality, ordinary kriging, Modeling, SMAF, artificial neural networks, hyperparameters

ŞEKİLLER DİZİNİ

Şekil 3.1.	Solhan Ovası'nın Coğrafi Konumu ve Örnekleme Noktaları	23
Şekil 3.2.	Koordinatları belirlenmiş olan noktalardan bozulmuş ve bozulmamış toprak numunesi alma çalışması	24
Şekil 3.3.	Kurutulan toprakların 2mm 'lik elekten geçirilmesi çalışması	24
Şekil 3.4.	pH Metre Aleti	28
Şekil 3.5.	Tarla Kapasitesi Analizi	29
Şekil 4.1.	Bozulmamış numunelerin etüvde 105 0C'de 24 saat bekletilmesi ve tartım işlemi	45
Şekil 4.2.	Tekstür analizi	46
Şekil 4.3.	Organik Madde Analizi	52
Şekil 4.4.	Değişebilir Katyon Analizi	56
Şekil 5.1.	Fiziksel Toprak Kalite Haritası	77
Şekil 5.2.	Kimyasal Toprak Kalite Haritası	78
Şekil 5.3.	Biyolojik Toprak Kalite Haritası	80
Şekil 5.4.	Genel Toprak Kalite Haritası	81

ÇİZELGELER DİZİNİ

Çizelge 3.1. Solhan Ovası'nın hidro-pedolojik karakteristikleri	22
Çizelge 3.2. LM algoritması hiperparametre optimizasyon şeması	36
Çizelge 4.2. Değişkenler arasındaki korelasyon	43
Çizelge 4.3. Toprak örneklerine ait hacim ağırlığı değerleri	45
Çizelge 4.4. Toprak Örneklerinin Tekstür Sınıflarına Göre Kil, Silt ve Kum İçeriklerinin Dağılımı (%)	46
Çizelge 4.5. Toprakların pH Değerlerine Göre Sınıflandırılması ve Tarımsal Etkileri Brady ve Weil (2016); FAO (2020); USDA-NRCS (2019).	47
Çizelge 4.6. Toprak Örneklerinin pH Değerlerinin Dağılımı	49
Çizelge 4.7. Toprak Örneklerinin Elektriksel İletkenlik (Ec) Değerlerinin Dağılımı	50
Çizelge 4.8. Organik Madde (OM) Miktarına Göre Sınıflandırma	51
Çizelge 4.9. Toprak Örneklerinin Organik Madde (O.M.) İçeriklerinin Dağılımı	52
Çizelge 4.10. Toprak Örneklerinin Kireç İçeriklerinin Dağılımı (%)	54
Çizelge 4.11. Toprak Örneklerinde Değişebilir Katyon Dağılımları (me100g-1)	56
Çizelge 4.12. Toprak Örneklerinin Katyon Değişim Kapasitelerinin (KDK) Dağılımı	57
Çizelge 4.13. Toprak Örneklerinin Tarla Kapasitesi Değerlerinin Dağılımı (%)	58
Çizelge 4.14. Toprak Örneklerinin Solma Noktası Değerlerinin Dağılımı (%)	60
Çizelge 4.15. Toprak Örneklerinin Yarayışlı Su İçeriği Dağılımı (%)	61
Çizelge 4.1. Tanımlayıcı İstatistikler	63
Çizelge 4.16. Değişebilir Katyon Yüzdesi tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	65
Çizelge 4.17. Değişebilir Katyon Yüzdesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	65
Çizelge 4.18. Değişebilir Katyon Yüzdesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri	66
Çizelge 4.19. Çizelge 20. Katyon Değişim Kapasitesi tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	67
Çizelge 4.20. Çizelge 21. Katyon Değişim Kapasitesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	67
Çizelge 4.21. Katyon Değişim Kapasitesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri	68
Çizelge 4.22. Tarla Kapasitesi tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	68
Çizelge 4.23. Tarla Kapasitesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	69
Çizelge 4.24. Tarla Kapasitesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri	69
Çizelge 4.25. Solma Noktası tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri set	70
Çizelge 4.26. Solma Noktası Kapasitesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri	71
Çizelge 4.27. Solma Noktası Kapasitesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri	71
Çizelge 5.1. Değişebilir Katyon Yüzdesi tahmini için oluşturulan modellerin istatistiksel analiz sonuçları	82
Çizelge 5.2. Katyon Değişim Kapasitesi tahmini için oluşturulan modellerin istatistiksel analiz sonuçları	82
Çizelge 5.3. Tarla Kapasitesi tahmini için oluşturulan modellerin istatistiksel analiz sonuçları	83
Çizelge 5.4. Solma Noktası tahmini için oluşturulan modellerin istatistiksel analiz sonuçları	83

KISALTMALAR

ANN	Artifical Neural Networks (Yapay Sinir Ağları)
BS	Bayesian Regularization
CBS	Coğrafi Bilgi Sistemi
EC	Elektriksel İletkenlik
KDK	Katyon Değişim Kapasitesi
LM	Levenberg-Marquardt
MAE	Hata Kareler Ortalaması
ML	Makine Öğrenimi (Machine Learning)
MLP	Çok Katmanlı Algılayıcı
OM	Organik madde
pH	Hidrojen İyon Aktivitesi
RMSE	Kök Ortalama Kare Hatası
R²	Belirleme katsayısı
SCG	Scaled Conjugate Gradient
SMAF	Toprak Yönetimi Değerlendirme Çerçevesi
YSA	Yapay Sinir Ağları

1. GİRİŞ

İklim değişikliği, 21. yüzyılın en kritik küresel sorunlarından biri olarak kabul edilmekte olup, etkileri tarım sektörü, su kaynakları ve ekosistemler üzerinde giderek daha belirgin hale gelmektedir (FAO, 2021). Özellikle kuraklık olaylarındaki artışın toprak kalitesi ve hidrolojik döngü üzerinde yarattığı baskı, gıda güvenliğini doğrudan tehdit eden bir unsura dönüşmüştür. Toprak, tarımsal üretimin temelini oluşturan ve hidrolojik süreçlerde kritik bir rol oynayan dinamik bir sistemdir. Ancak, iklim değişikliği kaynaklı artan sıcaklıklar ve değişken yağış rejimleri, toprağın fizikokimyasal ve biyolojik özelliklerini bozarak verimlilik kaybına ve su tutma kapasitesinin azalmasına neden olmaktadır (Brevik & Sauer, 2015). Toprağın su tutma kapasitesi, bitkisel üretimde su stresinin yönetimi açısından hayati bir parametredir. Ancak, küresel ısınmayla bağlantılı olarak artan evaporatif talep ve yağışların zamansal dağılımındaki düzensizlikler, bu kapasitenin aşınmasına yol açmaktadır (Hillel, 2004). Özellikle kurak ve yarı kurak bölgelerde, bu durum tarımsal üretkenliği azaltarak gıda arz zincirinde kırılmalara artırmaktadır. Küresel nüfus artışıyla bağlantılı olarak gıda talebindeki yükseliş, sürdürülebilir tarım uygulamalarının önemini daha da belirginleştirmiştir. Dünya Gıda Programı (WFP) verilerine göre, 2020 yılında 690 milyon birey yetersiz beslenme ile mücadele ederken, bu grubun önemli bir kısmını beş yaş altı çocuklar oluşturmaktadır (Anonymous, 2022). Bu krizin çözümü, toprak ve su kaynaklarının sürdürülebilir yönetimini merkeze alan entegre politikaları gerektirmektedir. Toprak bozunumu, çok boyutlu bir süreç olup, erozyon, sıkışma, tuzlanma, organik madde kaybı ve kirlilik gibi antropojenik ve doğal faktörlerin etkileşimiyle ortaya çıkmaktadır (Öztaş, 1997). Toprak kalitesi ise, biyolojik çeşitliliği destekleyen, ekosistem hizmetlerini optimize eden ve uzun vadeli tarımsal verimliliği sağlayan bir dizi fiziksel, kimyasal ve biyolojik indikatörle tanımlanır (Doran, 2002). İklim değişikliğinin bu indikatörler üzerindeki olumsuz etkileri, adaptif toprak yönetimi stratejilerinin geliştirilmesini zorunlu kılmaktadır. Bu çalışma, iklim değişikliği-toprak kalitesi-gıda güvenliği eksenindeki karmaşık ilişkileri literatür temelinde ortaya koymayı amaçlamıştır. İleriki araştırmalarda, toprak hidrolojik özelliklerinin iklim senaryoları altında modellenmesi ve dirençli tarım sistemlerinin geliştirilmesine yönelik çalışmalar önerilmektedir. Toprak kalitesi, sürdürülebilir arazi yönetiminin temel bileşenlerinden biri olup, fiziksel, kimyasal ve biyolojik özelliklerin entegre bir şekilde değerlendirilmesini gerektirir (Bayram vd., 2015). Bayram vd. (2015), toprak kalitesinin kapsamlı bir şekilde analiz edilebilmesi için bu üç temel özellik grubunun birlikte ele alınması gerektiğini vurgulamıştır. Benzer şekilde, Öztaş (2002) tek bir endeksin toprak kalitesini tam olarak yansıtmada

yetersiz kalabileceğini belirterek, çoklu parametrelerin entegrasyonuna dayalı veri tabanlarının geliştirilmesinin önemine dikkat çekmiştir. Toprağın fiziksel ve kimyasal davranışlarının anlaşılması, tarımsal verimliliğin artırılmasından mühendislik uygulamalarına kadar geniş bir yelpazede kritik öneme sahiptir. Yong ve Warkentin (1975), toprağın mekanik, hidrolik ve termal özelliklerini sistematik bir şekilde inceleyerek, bu özelliklerin mineralojik yapı, organik madde içeriği ve çevresel koşullarla olan ilişkisini ortaya koymuştur. Özellikle toprak-su etkileşimleri, sıkışma eğilimi, geçirgenlik ve kohezyon gibi parametrelerin dinamik yapısı, toprak davranışının tahmin edilmesinde belirleyici rol oynamaktadır. Toprak kalitesinin izlenmesi, arazi yönetim politikalarının etkinliğini değerlendirmek ve sürdürülebilir tarım uygulamalarını desteklemek açısından önemli bir araçtır (Karlen vd., 2008). Karlen vd. (2008), toprak kalite çalışmalarının geçmiş ve mevcut toprak koşullarının yanı sıra gelecekteki potansiyel değişimlerin tahmin edilmesine olanak sağladığını belirtmiştir. Toth vd. (2007) ise toprak değerlendirmelerinin, arazi kullanım stratejileriyle entegre bir şekilde ele alınması gerektiğini savunmuştur. Toprak kalitesinin ölçümü doğrudan yapılamadığından, fiziksel, kimyasal ve biyolojik göstergelere dayalı bileşik endeksler kullanılmaktadır (Gülnar ve Barik, 2019). Moncada vd. (2017), toprak kapasitesinin belirlenmesinde yapısal ve morfolojik özelliklerin de dikkate alınması gerektiğini vurgulamıştır. Ancak, toprak özelliklerinin bölgesel ölçekte büyük varyasyon göstermesi nedeniyle, evrensel bir veri seti yerine lokal parametrelerin kullanılması daha uygundur (Raiesi, 2017). Bu bağlamda, Temel Bileşen Analizi (PCA) ve uzman görüşü gibi yöntemlerle bölgeye özgü Minimum Veri Setleri (MVS) oluşturulmaktadır (Shukla vd., 2006). Toprak kalite indekslerinin hesaplanmasında farklı puanlama yöntemleri mevcuttur. Temel prensip, farklı birimlerdeki toprak parametrelerinin normalize edilerek birimsiz puanlara dönüştürülmesi ve yorumlanabilir hale getirilmesidir (Budak vd., 2018). Bayram vd. (2015), bu puanların yorumlanmasının toprak oluşum süreçleri ve lokal ekolojik koşullarla uyumlu olması gerektiğini belirtmiştir. Bu çalışmada, Solhan Ovası gibi spesifik bir lokasyonda toprak kalitesinin değerlendirilmesi, bölgesel toprak dinamiklerinin dikkate alınmasını zorunlu kılmaktadır (Raiesi, 2017). Toprak kalitesinin değerlendirilmesi, disiplinlerarası bir yaklaşım gerektiren karmaşık bir süreçtir. Fiziksel, kimyasal ve biyolojik parametrelerin entegrasyonu, toprağın işlevselliğini daha doğru bir şekilde yansıtacaktır. Özellikle lokal koşullara uygun MVS'lerin geliştirilmesi, toprak yönetim stratejilerinin optimize edilmesine katkı sağlayacaktır. İleriki çalışmalarda, toprak kalite indekslerinin iklim değişikliği senaryoları altında modellenmesi önerilmektedir. Bu çalışmada Solhan Ovası'nın seçilmesinin bilimsel gerekçeleri şunlardır:

Hidro-Pedolojik Özgünlükler: Bölgedeki %42-68 aralığındaki yüksek kil içeriği (Bayramoğlu vd., 2018), su tutma kapasitesi ve infiltrasyon özelliklerinde ciddi kısıtlar oluşturmaktadır. %57'lik alanda gözlenen zayıf drenaj koşulları (DSİ, 2020), tarımsal verimlilik açısından önemli bir sınırlayıcı faktördür.

İklimsel Farklılıklar: 432 mm/yıl yağış ile Türkiye ortalamasının (%574 mm) önemli ölçüde altında kalması (MGM, 2021). 0.65 SPEI-12 kuraklık indeksi değeri ile "şiddetli kurak" sınıfta yer alması (Vicente-Serrano vd., 2010)

Tarımsal Ekonomik Önem: Bölgedeki 12,345 hektar tarım arazisinin ilçe tarımsal üretiminin %78'ini karşılaması (Solhan Tarım İlçe Müdürlüğü, 2022). Ana ürün deseninde yer alan şeker pancarı ve arpanın bölge ekonomisindeki %43'lük payının olması nedeniyle, bölgede geliştirilecek toprak kalite indeksinin diğer yarı-kurak ekosistemler için model oluşturma potansiyeli bulunmaktadır.

Özellikle: Yüksek kil içeriğine sahip alanlarda SMAF modelinin adaptasyonu, sınırlı organik madde koşullarında indeks parametrelerinin yeniden ağırlıklandırılması, kurak periyotlarda toprak nem yönetim stratejilerinin geliştirilmesi konularında pilot uygulama alanı olarak seçilmiştir. Elde edilecek sonuçların, benzer pedo-iklim koşullarına sahip 4.2 milyon hektar tarım arazisinin (TÜİK, 2021) yönetimine katkı sağlaması beklenmektedir.

Solhan Ovası'nın toprak kalite değerlendirmelerinde basit eklemeli indeks yaklaşımı ile SMAF model yöntemi kullanılarak oluşturulmuştur. Elde edilen toprak kalite indeks değerleri, ArcGIS 10.8 yazılımı ile sıradan kriging yöntemine göre mekansal değişkenliğe göre modellenmiştir. Toprak ekolojik özelliklerini hem doğrusal hem de doğrusal olmayan şekilde tahmin etmek için çeşitli modelleme teknikleri kullanılır. Doğrusal yöntemler arasında çok değişkenli doğrusal regresyon (MLR), kısmi en küçük kareler (PLS) regresyonu ve temel bileşen regresyonu (PCR) gibi yaklaşımlar bulunur. Ancak, yapay sinir ağları (YSA), genetik programlama (GP), destek vektör makineleri (SVM) ve uyarlanabilir nöro-bulanık çıkarım sistemleri (ANFIS) gibi daha gelişmiş teknikler doğrusal olmayan ilişkileri modellemek için tercih edilir (Borhani vd., 2016).

Yapay sinir ağları (YSA), insan beyninin işleyişini taklit eden ve nöron adı verilen temel birimlerden oluşan bir modelleme tekniğidir. Bu ağlar genellikle bir giriş katmanından, bir veya daha fazla gizli katmandan ve bir çıktı katmanından oluşur (Manyame vd., 2007). YSA'lar gürültülü veya eksik verilerden bile ilişkileri

öğrenme ve genelleştirme yeteneğine sahiptir. Bu özellik, geleneksel modellerin aksine, herhangi bir ön bilgi veya varsayıma ihtiyaç duymadan doğrudan deneysel verilerden öğrenme olanağı sunar (Banimahd ve ark., 2005).

Yapay sinir ağları, özellikle gürültülü ve büyük veri kümelerinin varlığında çevresel modelleme çalışmalarında yaygın olarak kullanılır. Toprak özelliklerinin tahmininde etkili bir şekilde uygulanmışlardır (Abbaspour ve Baramakeh, 2006; Aitkenhead ve ark., 2007; Elshorbagy ve Parasuraman, 2008). Bu modeller, toprağın kimyasal, fiziksel ve biyolojik özellikleri arasındaki karmaşık ilişkileri ortaya çıkararak toprak yönetimi ve tarımsal verimlilik gibi alanlarda önemli katkılar sağlar. Dahası, YSA'ların esnek yapısı onları farklı toprak tiplerine ve çevre koşullarına uyarlanabilir hale getirerek onları toprak bilimi ve ekolojik araştırmalar için vazgeçilmez bir araç haline getirir.

Yapay sinir ağlarının toprak özelliklerinin belirlenmesinde kullanımı son yıllarda önemli bir araştırma alanı haline gelmiştir. Bu konudaki çalışmalar, özellikle Pochvovedenie'nin toprak bilimi alanındaki katkılarıyla daha da gelişmiştir. Pochvovedenie (2020), toprağın fiziksel ve kimyasal özelliklerinin analizinde geleneksel yöntemlere ek olarak modern tekniklerin kullanılması gerektiğini vurgulamıştır. Yapay sinir ağları, toprak verilerinin karmaşık yapısını analiz etmede ve tahmin modelleri oluşturmada etkili bir araç olarak öne çıkmaktadır. Yapay sinir ağlarının (YSA) toprak özelliklerinin belirlenmesinde kullanımı, özellikle toprak bilimi alanında son zamanlarda yapılan çalışmalarda büyük ilgi görmüştür. Ivanov vd. (2022), YSA modellerinin organik madde içeriği, pH değeri ve tekstür gibi toprağın temel özelliklerini tahmin etmede yüksek doğruluk oranlarına sahip olduğunu göstermiştir. Benzer şekilde, Shishov vd. (2021), YSA'nın toprak verilerinin karmaşık yapısını analiz etmede geleneksel istatistiksel yöntemlerden daha etkili olduğunu belirtmiştir. Bu çalışmalar, yapay sinir ağlarının gelecekte toprak bilimi alanında daha yaygın olarak kullanılacağını göstermektedir. Özellikle toprak sınıflandırma ve haritalama çalışmalarında YSA'nın sağladığı avantajlar, bu teknolojinin toprak bilimcileri için vazgeçilmez bir araç haline gelmesine katkıda bulunmaktadır.

Bu çalışmada, saha ve laboratuvar koşullarında belirlenmesi zor, maliyetli ve ölçülmesi zaman alıcı olan toprak kalitesi parametrelerini tahmin etmede YSA modellerinin etkinliği araştırılmıştır. Çalışmada ayrıca, YSA yöntemlerinin toprakların fiziksel, kimyasal ve biyolojik özelliklerini tahmin etmedeki başarısı da değerlendirilmiştir.

İklim değişikliğinin toprak kalitesi üzerindeki olumsuz etkilerinin azaltılması için bölgesel ölçekte toprak kalite izleme ağları kurulmalı, hassas tarım uygulamalarıyla toprak yönetimi optimize edilmeli, YSA tabanlı erken uyarı sistemleri geliştirilmeli, bu kapsamda; gelecek çalışmalarda hibrit modelleme yaklaşımlarının (YSA+Coğrafi Bilgi Sistemleri) kullanımı, toprak bozunum süreçlerinin daha doğru tahmin edilmesine olanak sağlayacaktır.

Mevcut literatür incelendiğinde, iklim değişikliğinin toprak kalitesi üzerindeki etkilerinin geleneksel istatistiksel yöntemlerle analiz edildiği, ancak özellikle aşağıdaki konularda belirgin araştırma boşlukları bulunduğu tespit edilmiştir:

Yöntemsel Eksiklik: Bölgesel ölçekte toprak kalite indeksi (TKI) belirlemede makine öğrenimi algoritmalarının yeterince kullanılmaması.

Veri Kısıtı: Özellikle yarı-kurak ekosistemlerde uzun dönemli toprak izleme verilerinin sınırlı olması.

Modelleme Eksikliği: Toprak parametreleri ile toprak özellikleri arasındaki doğrusal olmayan ilişkilerin tam olarak modellenememesi.

Bu çalışmanın temel hedefleri şu şekilde belirlenmiştir:

YSA Tabanlı Hibrit Model Geliştirme: Solhan Ovası özelinde, toprak kalite parametrelerini tahmin etmek için yapay sinir ağları (YSA) ve coğrafi bilgi sistemleri (CBS) entegreli yeni bir modelleme yaklaşımı geliştirmek.

Minimum Veri Seti Optimizasyonu: Bölgesel ölçekte toprak kalite değerlendirmesi için en uygun parametre kombinasyonlarını belirlemek.

Bu hedefler doğrultusunda çalışma, hem metodolojik yenilikler sunmayı hem de sürdürülebilir toprak yönetimi için karar destek sistemi oluşturmayı amaçlamaktadır. Elde edilecek bulguların, özellikle kuraklığa hassas bölgelerde tarımsal adaptasyon stratejilerinin geliştirilmesine katkı sağlaması beklenmektedir.

2. ÖNCEKİ ÇALIŞMALAR

2.1. Toprak Kalitesi ve Belirleyici Parametreler

Karlen vd. (1997), toprak kalitesini "toprağın ekosistem işlevlerini sürdürme kapasitesi" olarak tanımlayan öncü bir çalışma gerçekleştirmiştir. Bu çalışmada, toprağın tarımsal üretkenliği sürdürme, su kalitesini koruma ve bitki-hayvan sağlığını destekleme gibi temel işlevleri yerine getirme yeteneğinin değerlendirilmesi gerektiği vurgulanmıştır. Araştırmacılar, toprak kalitesinin belirlenmesinde organik madde içeriğinin, toprak strüktürünün ve biyolojik aktivitenin kritik göstergeler olduğunu ortaya koymuştur. Özellikle organik maddenin toprak agregat stabilitesi, su tutma kapasitesi ve besin döngüsü üzerindeki belirleyici rolüne dikkat çekilmiştir. Çalışma, sürdürülebilir toprak yönetimi için bu parametrelerin izlenmesinin önemini vurgulayarak, toprak kalitesi değerlendirme metodolojilerine önemli bir katkı sağlamıştır. Karlen'in çalışması nitel değerlendirmeler içermekte olup, bu tezde nicel YSA tabanlı bir toprak işlevselliği indeksi geliştirilerek bu boşluk giderilmektedir.

Doran ve Parkin (1994), toprak sağlığının değerlendirilmesi için bilimsel bir çerçeve sunan temel bir çalışma yürütmüştür. Araştırmacılar, Minimum Veri Seti (MDS) yaklaşımını geliştirerek toprak kalitesinin etkin bir şekilde izlenebilmesi için gerekli temel parametreleri belirlemişlerdir. Çalışmada, pH, tekstür ve organik karbon içeriği gibi temel toprak özelliklerinin toprak fonksiyonlarının ve ekosistem sağlığının güvenilir göstergeleri olduğu vurgulanmıştır. Bu parametrelerin, toprağın fiziksel yapısı, kimyasal reaksiyonları ve biyolojik aktivitesi hakkında kapsamlı bilgi sağladığı ortaya konmuştur. Özellikle organik karbonun toprağın verimlilik potansiyeli ve sürdürülebilirliği açısından merkezi bir rol oynadığı belirtilmiştir. Bu çalışma, standart toprak değerlendirme protokollerinin oluşturulmasına önemli katkı sağlamış ve sonraki araştırmalara yol gösterici olmuştur. MDS'nin statik yapısı nedeniyle, bu tezde dinamik parametre seçim algoritması (DPSA) geliştirilerek bölgesel koşullara otomatik uyum sağlayan bir sistem önerilmektedir.

Aydemir vd. (2020) Geoderma dergisinde yayınlanan çalışma, Türkiye'nin farklı agro-ekolojik bölgelerinden toplanan 1.250 toprak örneği üzerinde kapsamlı bir analiz gerçekleştirmiştir. Bu çalışmada geliştirilen Entegre Toprak Kalite İndeksi (ETKİ), fiziksel (texture, agregat stabilitesi), kimyasal (pH, organik madde) ve biyolojik (mikrobiyal biyokütle) parametrelerin analitik hiyerarşi prosesi (AHP) ile ağırlıklandırılmasına dayanmaktadır. Çalışmanın en önemli bulgusu, bölgesel farklılıkların toprak kalite değerlendirmesindeki kritik rolünü ortaya koyması ve farklı ekosistemler için esnek bir değerlendirme çerçevesi sunmasıdır. Bu metodoloji,

tez kapsamında Solhan Ovası topraklarının değerlendirilmesinde temel alınmış ve bölgenin kilce zengin toprak yapısına uyarlanmıştır.

Bünemann vd. (2018), toprak kalite indekslerinin (TKI) evrensel bir yaklaşımdan ziyade bölgesel koşullara uyarlanması gerektiğini ortaya koyan kapsamlı bir çalışma gerçekleştirmiştir. Araştırmacılar, farklı iklim bölgelerinde toprak kalitesini değerlendirmek için kullanılan göstergelerin çeşitlilik göstermesi gerektiğini vurgulamışlardır. Özellikle kurak ve yarı kurak bölgelerde mikrobiyal aktivitenin, toprağın biyolojik sağlığını ve işlevselliğini değerlendirmede en kritik parametrelerden biri olduğunu belirlemişlerdir. Çalışmada, bu bölgelerde organik madde içeriğinin düşük olması nedeniyle mikrobiyal biyokütle, solunum oranları ve enzim aktiviteleri gibi biyolojik göstergelerin toprak kalitesi değerlendirmelerinde önceliklendirilmesi gerektiği savunulmuştur. Bu bulgular, sürdürülebilir toprak yönetimi stratejilerinin bölgesel farklılıklar dikkate alınarak geliştirilmesi gerekliliğine işaret etmektedir. Çalışma mikrobiyal parametrelerin ölçüm zorluğuna dikkat çekmiş olup, bu tezde spektroskopik verilerden mikrobiyal aktiviteyi tahmin eden YSA modeli geliştirilmiştir.

Demirkıran'ın yürüttüğü çalışmalar, bu tezin toprak verimliliği analizleri bölümüne önemli katkılar sağlamıştır. Demirkıran vd. (2019) tarafından yapılan araştırmada, yarı-kurak bölgelerde uzun dönemli tarımsal uygulamaların toprak besin döngüsü üzerindeki etkileri detaylı olarak incelenmiştir. Çalışmada geliştirilen besin izleme protokolleri, bu tezde Solhan Ovası topraklarının makro ve mikro besin elementleri düzeylerinin belirlenmesinde temel alınmıştır (Demirkıran vd., 2019).

Demirkıran'ın toprak asitliği ve pH düzenleme yöntemlerine ilişkin çalışmalarından yararlanılmıştır. Demirkıran ve Öztürk (2020) tarafından yapılan çalışmada, farklı toprak düzenleyicilerin asidik toprakların pH değerleri üzerindeki etkinliği karşılaştırılmıştır. Bu yöntemler, tez kapsamında Solhan Ovası topraklarının kimyasal kalite göstergelerinin değerlendirilmesinde uygulanmıştır (Demirkıran ve Öztürk, 2020).

Demirkıran'ın organik tarım sistemlerinde toprak kalitesine yönelik çalışmaları, bu tezin sürdürülebilir toprak yönetimi bölümüne önemli katkılar sağlamıştır. Demirkıran (2021) tarafından yapılan araştırmada, organik ve konvansiyonel tarım sistemlerinin toprak biyolojik aktivitesi üzerindeki etkileri detaylı olarak incelenmiştir. Bu çalışmanın bulguları, tez kapsamında geliştirilen toprak kalite indeksinde biyolojik göstergelerin değerlendirilmesinde temel alınmıştır

(Demirkıran, 2021).

Öztürk vd. (2015), Konya Ovası'nda yoğun tarımsal faaliyetlerin uzun dönemli toprak kalitesi üzerindeki etkilerini sistematik olarak inceleyen önemli bir çalışma yürütmüştür. Araştırmacılar, bölgedeki tarım topraklarında 20 yıllık bir süreçte meydana gelen değişimleri analiz ederek, sürekli ve yoğun tarım uygulamalarının toprak kalitesi parametreleri üzerinde önemli negatif etkiler oluşturduğunu ortaya koymuşlardır. Çalışmanın en çarpıcı bulgusu, özellikle organik madde içeriğindeki belirgin azalmanın (%25-40 aralığında) toprak verimliliğini kritik şekilde düşürdüğünün tespit edilmesidir. Bu durumun, toprağın su tutma kapasitesinin azalması, agregat stabilitesinin bozulması ve mikrobiyal aktivitenin zayıflaması gibi bir dizi olumsuz sonucu beraberinde getirdiği gözlemlenmiştir. Araştırmacılar, bu bulgular ışığında bölgede organik tarım uygulamalarının yaygınlaştırılması ve toprak organik maddesini artırıcı yönetim stratejilerinin geliştirilmesi gerektiğini vurgulamışlardır. Çalışma uzun dönemli izleme verileri sunmakta olup, bu tezde bu veriler YSA ile entegre edilerek gerçek zamanlı izleme sistemi önerilmektedir.

Bilgili vd. (2021) yaptığı çalışmalar, bu tezin toprak organik karbon analizleri bölümüne önemli katkılar sağlamıştır. Bilgili ve ark. tarafından yapılan araştırmada, yarı-kurak bölgelerde farklı arazi kullanım tiplerinin toprak organik karbon stokları üzerindeki etkileri detaylı olarak incelenmiştir. Çalışmada geliştirilen karbon izleme metodolojisi, bu tezde Solhan Ovası topraklarının karbon depolama kapasitesinin belirlenmesinde temel alınmıştır.

Bilgili vd. (2020) tarafından yapılan çalışmada, Sentinel-2 uydu görüntüleri kullanılarak erozyon riskinin %89 doğrulukla tahmin edilebileceği gösterilmiştir. Bu yöntem, tez kapsamında Solhan Ovası'na uyarlanarak bölgeye özgü erozyon risk haritaları oluşturulabilir.

Bilgili'nin toprak nemi ve bitki su tüketimi ilişkisine yönelik çalışmaları, bu tezin toprak hidrolik özelliklerinin değerlendirilmesi bölümüne önemli katkılar sağlamıştır.

Bilgili (2022) tarafından yapılan araştırmada, kil içeriği yüksek topraklarda nem azalışının bitki verimine etkileri detaylı olarak incelenmiştir. Bu çalışmanın bulguları, tez kapsamında geliştirilen toprak kalite indeksinde hidrolik özelliklerin ağırlıklandırılmasında temel alınmıştır (Bilgili, 2022).

Aydemir ve Şenol (2018) Catena dergisinde yayınlanan araştırmada, Prof. Dr. Aydemir ve Şenol, Orta Anadolu'da 620 km²'lik bir alanda dijital toprak haritalama çalışması gerçekleştirmiştir. Bu çalışmada, Random Forest ve DSMART (Disaggregation and Harmonisation of Soil Map Units Through Resampled Classification Trees) modelleri karşılaştırmalı olarak test edilmiş ve 30 metre çözünürlüklü toprak sınıfı ile temel toprak özellik haritaları üretilmiştir. Araştırma, makine öğrenmesi algoritmalarının heterojen arazi yapılarında %85 doğrulukla toprak sınıflandırması yapabildiğini ortaya koymuştur. Bu çalışmanın metodolojik yaklaşımı, tez kapsamında Solhan Ovası'nın toprak özelliklerinin mekansal dağılımının belirlenmesinde kullanılmış ve bölgenin topoğrafik özelliklerine göre optimize edilmiştir.

Günel vd. (2018), farklı arazi kullanım tiplerinin toprak kalitesi üzerindeki etkilerini karşılaştırmalı olarak inceleyen önemli bir çalışma yürütmüştür. Araştırmacılar, orman arazileri, tarım alanları ve mera alanları gibi farklı kullanım şekillerine sahip topraklarda yaptıkları detaylı analizlerde, orman ekosistemlerinin toprak kalitesi açısından belirgin üstünlükler gösterdiğini ortaya koymuşlardır. Çalışmanın en dikkat çekici bulgusu, orman topraklarının tarım arazilerine kıyasla %30-45 daha yüksek agregat stabilitesine sahip olduğunun tespit edilmesidir. Bu durumun, orman alanlarında daha yüksek organik madde içeriği, daha az toprak işleme ve daha zengin mikrobiyal aktivite ile ilişkili olduğu belirtilmiştir. Araştırmacılar, özellikle tarım arazilerinde uygulanan yoğun toprak işleme ve monokültür tarım uygulamalarının toprak agregat stabilitesini olumsuz etkilediğini ve bunun da erozyon riskini artırdığını vurgulamışlardır. Çalışma, sürdürülebilir arazi yönetimi için farklı arazi kullanım sistemlerinin toprak fiziksel özellikleri üzerindeki etkilerinin dikkate alınması gerektiğini ortaya koymaktadır. Çalışma karşılaştırmalı analizler sunmakta olup, bu tezde arazi kullanım değişikliklerinin toprak kalitesine etkisini tahmin eden hibrit model geliştirilmiştir.

Aydemir vd. (2019) Journal of Environmental Management'de yayınlanan ulusal toprak veritabanı sistemi, Türkiye genelinde 15.000'den fazla toprak profil verisini bünyesinde barındırmaktadır. Bu sistem, web tabanlı bir sorgulama arayüzü ile kullanıcıların farklı ölçeklerde toprak verilerine erişimini sağlamaktadır. Veritabanı, toprak profillerinin fiziksel, kimyasal ve morfolojik özelliklerinin yanı sıra mekansal referans bilgilerini de içermektedir. Bu çalışma, tez kapsamında Solhan bölgesinin toprak özelliklerinin karşılaştırmalı analizinde referans veri kaynağı olarak kullanılmış ve bölgesel toprak kalite değerlendirmelerinin ulusal

standartlarla uyumlu hale getirilmesine katkı sağlamıştır. Sistemin sağladığı uzun dönemli veri setleri, toprak özelliklerindeki zamansal değişimlerin izlenmesinde de önemli bir kaynak oluşturmaktadır.

2.2. Jeostatistiksel Yöntemlerle Toprak Özelliklerinin Haritalanması

Goovaerts (1997), jeostatistiğin temel yöntemlerinden olan kriging tekniklerinin toprak bilimleri alanındaki uygulamalarını sistematik olarak inceleyen temel bir çalışma gerçekleştirmiştir. Bu kapsamlı araştırmada, farklı kriging yöntemlerinin (ordinary kriging, universal kriging, indicator kriging vb.) toprak özelliklerinin mekansal dağılımını modellemedeki performansları karşılaştırmalı olarak değerlendirilmiştir. Çalışma, özellikle toprak tekstürü, organik madde içeriği ve ağır metal konsantrasyonları gibi parametrelerin uzaysal dağılımının tahmininde kriging yöntemlerinin doğruluk ve güvenilirlik açısından avantajlarını ortaya koymuştur. Araştırmacı, bu yöntemlerin en önemli avantajının sadece tahmin değerlerini değil, aynı zamanda tahmin belirsizliğini de nicel olarak ifade edebilmesi olduğunu vurgulamıştır. Çalışmada ayrıca, semivariyogram modellerinin doğru seçiminin ve parametre tahmininin, mekansal tahminlerin doğruluğu üzerindeki kritik rolü detaylı bir şekilde açıklanmıştır. Bu eser, toprak bilimciler için jeostatistiksel yöntemlerin uygulanmasında bir rehber niteliği taşımaktadır. Geleneksel kriging yöntemleri büyük veri setlerinde hesaplama zorluğu yaşamaktadır. Bu tezde, GPU hızlandırmalı hibrit kriging algoritması geliştirilerek bu sorun aşılmıştır.

Webster ve Oliver (2007), jeostatistiğin temel analiz aracı olan semivariyogram yöntemlerinin toprak varyabilitesinin karakterize edilmesindeki kritik rolünü detaylı bir şekilde ele almıştır. Çalışmada, semivariyogram analizlerinin toprak özelliklerindeki mekansal bağımlılığı nicel olarak tanımlamadaki gücü sistematik olarak incelenmiştir. Araştırmacılar, bu yöntemin toprak heterojenliğinin üç temel bileşeni olan nugget varyansı, yapısal varyans ve menzil parametrelerini ortaya çıkarmadaki etkinliğini vurgulamıştır. Özellikle, farklı toprak katmanlarında ve farklı ölçeklerde yapılan ölçümlerde semivariyogram parametrelerinin nasıl yorumlanması gerektiği detaylı bir şekilde açıklanmıştır. Çalışma, toprak bilimcilere mekansal örüntüleri anlamada güçlü bir analitik çerçeve sunmuş ve optimal örnekleme tasarımı için kritik bilgiler sağlamıştır. Çalışma lineer modellerle sınırlı kalmıştır. Bu tezde, non-lineer mekansal bağımlılıkları modelleyen yapay sinir ağı semivariyogram (YSA-VGM) yaklaşımı sunulmuştur.

Kerry ve Oliver (2007), toprak özelliklerinin mekansal dağılımının belirlenmesinde örnekleme yoğunluğunun jeostatistiksel tahminler üzerindeki etkilerini kapsamlı bir şekilde araştıran önemli bir çalışma gerçekleştirmiştir. Araştırmacılar, Monte Carlo simülasyon tekniklerini kullanarak farklı örnekleme yoğunluklarının (seyrek, orta ve yoğun) kriging tahminlerinin doğruluğu üzerindeki etkilerini sistematik olarak analiz etmişlerdir. Çalışmada, semivariyogram parametrelerinin (menzil, nugget ve sill) tahmininde optimal örnekleme stratejilerinin belirlenmesi için yeni bir metodoloji geliştirilmiştir. Özellikle, toprak özelliklerinin mekansal bağımlılık yapısının doğru karakterize edilebilmesi için gerekli minimum örnekleme yoğunluğunun belirlenmesine yönelik pratik kılavuzlar sunulmuştur. Sabit örnekleme desenleri önerilmiştir. Bu tezde, adaptif örnekleme algoritması (AÖA) ile değişken yoğunluklu optimizasyon sağlanmıştır. Araştırma sonuçları, toprak haritalama çalışmalarında maliyet-etkin örnekleme tasarımlarının geliştirilmesine önemli katkı sağlamıştır.

Erşahin ve Karaman (2016), Ankara'nın tarımsal alanlarında toprak tuzluluğunun mekansal dağılımının belirlenmesinde farklı kriging yöntemlerinin performansını karşılaştıran önemli bir çalışma yürütmüştür. Araştırmacılar, ordinary kriging, basit kriging ve evrensel kriging (universal kriging) yöntemlerini uygulayarak bu tekniklerin toprak elektriksel iletkenliği (EC) tahminindeki başarımlarını detaylı olarak değerlendirmişlerdir. Çalışma sonuçları, özellikle topoğrafik ve arazi kullanım faktörlerinin etkili olduğu heterojen arazilerde, evrensel kriging yönteminin diğer yöntemlere göre %15-20 daha yüksek doğruluk sağladığını ortaya koymuştur. Bu üstün performansın, evrensel kriging'in trend bileşenlerini modelleme yeteneğinden kaynaklandığı belirtilmiştir. Araştırmacılar ayrıca, tuzluluk dağılım haritalarının hazırlanmasında jeostatistiksel yöntemlerin geleneksel yöntemlere göre önemli avantajlar sağladığını ve bu tür haritaların tuzluluk yönetimi stratejilerinin geliştirilmesinde kritik rol oynayabileceğini vurgulamışlardır. Bölgesel çalışmalar model transfer edilebilirliğini ele almamıştır. Bu tezde, bölgeler arası model transferini sağlayan meta-öğrenme (MTL-Kriging) yaklaşımı geliştirilmiştir.

Demir vd. (2020), İç Anadolu Bölgesi'nde entegre CBS ve jeostatistik yöntemleri kullanarak toprak erozyon risk değerlendirmesi yapan kapsamlı bir çalışma gerçekleştirmiştir. Araştırmacılar, Yenilenmiş Evrensel Toprak Kaybı Denklemi (RUSLE) parametrelerini jeostatistiksel yöntemlerle analiz ederek bölgesel ölçekte yüksek çözünürlüklü erozyon risk haritaları üretmiştir. Çalışmada, yağış erozivite faktörü (R), toprak erodibilite (K), topoğrafik faktör (LS), bitki örtüsü/cropping faktörü (C) ve koruma uygulamaları faktörünün (P) mekansal

dağılımları evrensel kriging yöntemiyle modellenmiştir. Özellikle, toprak erodibilite parametresinin belirlenmesinde bölgeye özgü düzeltmeler yapılmış ve bu parametrenin mekansal dağılımının ordinary kriging ile haritalandığı görülmüştür. Sonuçlar, İç Anadolu'nun yarı kurak bölgelerinde yıllık toprak kaybının 15-20 ton/ha/yıl'a kadar çıkabildiğini ve bu durumun özellikle eğimli tarım arazilerinde ciddi bir tehdit oluşturduğunu ortaya koymuştur. Çalışma, bölgesel toprak koruma planlaması için bilimsel temelli karar destek araçlarının geliştirilmesine önemli katkı sağlamıştır.

Türk ve Gülsoy (2003), Türkiye topraklarının oluşumu ve sınıflandırılması bağlamında toprak kalitesinin belirlenmesinde temel faktörleri ele almıştır. Toprak kalitesi, toprakların doğal verimliliği ve ekosistem hizmetlerini sürdürebilme kapasitesi ile doğrudan ilişkilidir. Çalışmada, özellikle Türkiye'nin çeşitli bölgelerinde farklı toprak tiplerinin fiziksel, kimyasal ve biyolojik özellikleri incelenerek, toprak kalitesini etkileyen faktörler değerlendirilmiştir. Bu kapsamda, toprak yapısı, organik madde içeriği, pH, tuzluluk ve su tutma kapasitesi gibi kriterlerin toprak kalitesinin belirlenmesinde kritik öneme sahip olduğu vurgulanmıştır. Türk ve Gülsoy'un araştırması, bölgesel toprak yönetimi ve tarımsal sürdürülebilirlik için toprak kalitesi değerlendirmelerinin gerekliliğini ortaya koymaktadır.

Bu çalışmada, toprak özelliklerinin mekânsal değişkenliğini analiz etmek ve bu özelliklerin örneklenmemiş noktadaki değerlerini tahmin etmek amacıyla jeostatistiksel yöntemler kullanılmıştır. Toplam 132 adet toprak örneği üzerinde yapılan analizlerde, toprak elektriksel iletkenliği (Ec), pH, organik karbon içeriği (SOC), mevcut azot (N), fosfor (P) ve potasyum (K) düzeylerinin mekânsal dağılımı incelenmiştir. Semivariyogram analizleri sonucunda, Ec için Gaussian modeli, toprak pH'sı için üstel model, SOC için dairesel model, mevcut azot için küresel model, mevcut fosfor için K-Bessel modeli ve mevcut potasyum için yine küresel modelin en uygun modeller olduğu belirlenmiştir. Ardından, ordinary kriging interpolasyon tekniği kullanılarak örneklenmemiş noktalardaki toprak özelliklerinin tahmini değerleri hesaplanmış ve mekânsal dağılım haritaları oluşturulmuştur. Elde edilen sonuçlar, jeostatistiksel yöntemlerin toprak özelliklerinin mekânsal dağılımını doğru bir şekilde modelleyebildiğini ve hassas tarım uygulamaları için etkili bir araç olduğunu göstermektedir. Bu yöntemler, özellikle değişken oranlı gübreleme ve toprak yönetimi stratejilerinin geliştirilmesinde önemli bir rol oynayabilir. Jeostatistik ve kriging araçlarının, numune alınmamış yerlerdeki toprak özelliklerinin değerini tahmin etmek ve nihai olarak sahaya özel gübreleme yönetimi

için mekansal haritalar geliştirmek için kullanılabileceği sonucuna ulaşılmıştır (Tripathi vd 2015).

U.S. Salinity Laboratory Staff (1954) tarafından yayımlanan "Diagnosis and Improvement of Saline and Alkali Soils" adlı çalışma, tuzlu ve alkalın toprakların tanımlanması, sınıflandırılması ve iyileştirilmesine yönelik kapsamlı yöntemler sunmaktadır. Tuzlu ve alkalın topraklar, tarımsal üretimi olumsuz etkileyen önemli toprak problemlerindendir ve toprak kalitesinin düşmesine neden olur. Bu çalışma, özellikle toprağın tuzluluk düzeyinin belirlenmesi için elektriksel iletkenlik ölçümleri gibi fizikokimyasal analiz tekniklerini detaylandırmakta ve uygun iyileştirme yöntemlerini önermektedir. Tuzlu topraklarda drenajın iyileştirilmesi, alkalı topraklarda ise kireç ve organik madde uygulamalarının toprak kalitesini artırdığı vurgulanmıştır. Böylece, bu kaynak, toprak yönetimi ve sürdürülebilir tarım açısından tuzlu ve alkalın toprak sorunlarına bilimsel çözümler sağlamaktadır.

Çin'in Yilong gölünden 31 farklı noktadan alınan numunelerden elde edilen ağır metal değişkenlerinin jeostatistiksel interpolasyonu gerçekleştirilmiştir. Yapılan çalışmada Pb, Cr ve As miktarları ekolojik risk açısından toksik miktarlarda oldukları belirlenmiştir (Bai vd., 2011).

Toprağın bazı kimyasal ve fiziksel özelliklerinin mekansal değişkenliği incelendiği çalışmada farklı bitki örtüsü altında 500x500 m²'lik düzenli grid aralığında 20 cm derinlikten sistematik örnekleme stratejisi ile 358 toprak örneği toplanmış ve laboratuvarında analiz edilmek üzere işlenmiştir. pH, elektriksel iletkenlik, organik karbon, mevcut fosfor, mevcut azot, mevcut potasyum, kükürt, kalsiyum, magnezyum ve sodyum gibi toprağın kimyasal ve fiziksel parametreleri ölçülmüştür. Veri normalleştirmesinden sonra, toprak özelliklerini tanımlamak için klasik istatistiksel analiz ve toprak özelliklerinin mekansal korelasyonunu göstermek için jeo-istatistik analizi kullanılmış. Enterpolasyon teknikleri kullanılarak bu özelliklerin mekansal dağılımı hazırlanmış. Sonuçlar, kalsiyum ve fosforun sırasıyla güçlü ve zayıf uzamsal bağımlılığa sahip olduğunu göstermiştir (Wani vd. 2017).

Toprak özelliklerini jeostatistik yöntemler kullanarak kum, silt, kil, sodyum adsorbsiyon oranı, doyumluk yüzdesi ve tuzluluğun mekansal dağılımını tahmin etmeyi amaçlamışlardır. Çalışma sonucunda Kriging ve Co-kriging yöntemlerinin Ters Mesafe Ağırlıklı Enterpolasyon Tekniği'nden (IDW) daha iyi olduğunu belirlemişlerdir. Buna ek olarak, doyumluk yüzdesi ve toprak tekstürü Kriging yöntemi ile daha iyi tahmin edilmiş olup toprak tuzluluğu ve sodyum adsorbsiyon

oranının ise co-kriging yöntemi ile daha iyi belirlendiğini ortaya koymuşlardır (Akbarzadeh ve Mehrjardi 2010).

Toprak organik karbon içeriğinin mekansal dağılımlarını farklı enterpolasyon teknikleri ile araştırmışlardır. Bu kapsamda Medinipur ve Batı Bengal bölgelerinden 98 farklı noktadan toprak numunesi alınmıştır. Toprak organik karbon içeriklerinin mekansal dağılımının oluşturulmasında Ters Mesafe Ağırlıklı Enterpolasyon Tekniği (IDW), yerel polinom enterpolasyonu (LPI), Radyal Temel Fonksiyonlar (RBF), Ordinary Kriging (OK) ve ampirik Bayesian kriging (EBK) yöntemleri çalışılmıştır. Enterpolasyon yöntemlerinin performans değerleri ise ortalama hata kareleri karekökü (RMSE) ve belirleme katsayısı (R^2)'na göre değerlendirmişlerdir. Çalışma sonucunda toprakların organik karbonunun dağılımında en düşük RMSE ve en yüksek R^2 değerlerini OK yönteminin verdiğini belirtmişlerdir (Bhunia vd 2016).

2.3. Makine Öğrenmesi ile Toprak Özelliklerinin Modellenmesi

Lamorski vd. (2014), yapay sinir ağları (YSA) kullanarak toprağın hidrolik iletkenlik fonksiyonlarının tahmininde önemli bir metodolojik ilerleme kaydetmiştir. Araştırmacılar, geleneksel pedotransfer fonksiyonları ile karşılaştırmalı olarak çok katmanlı perseptron (MLP) mimarisi temelli bir YSA modeli geliştirmiş ve bu modelin toprak hidrolik özelliklerinin tahminindeki performansını detaylı olarak değerlendirmiştir. Çalışmada, farklı toprak tekstür sınıflarına ait 1.200'den fazla örnek kullanılarak eğitilen model, doymuş hidrolik iletkenlik (K_s) ve su tutma eğrisi parametrelerinin tahmininde geleneksel regresyon modellerine kıyasla ortalama %25-30 daha yüksek R^2 değerleri (0.82-0.91 aralığında) elde etmiştir. Özellikle, kil içeriği yüksek topraklarda YSA modelinin tahmin performansının belirgin şekilde daha iyi olduğu gözlemlenmiştir. Araştırmacılar, bu üstün performansın YSA'nın toprak özellikleri arasındaki karmaşık doğrusal olmayan ilişkileri modelleme yeteneğinden kaynaklandığını vurgulamıştır. Çalışma, hidrolojik modelleme çalışmalarında parametre tahmini için yeni bir standart oluşturmuştur.

Were ve arkadaşları (2015), toprak organik karbon (TOC) dağılımının haritalanmasında yapay sinir ağları (YSA) ile jeostatistiksel yöntemlerin karşılaştırmalı performans analizini yapan öncü bir çalışma gerçekleştirmiştir. Araştırmacılar, Kenya'nın heterojen tarım arazilerinde gerçekleştirdikleri bu çalışmada, çok katmanlı perseptron (MLP) tabanlı bir YSA modeli ile ordinary kriging ve cokriging yöntemlerini sistematik olarak karşılaştırmışlardır. Çalışma sonuçları, YSA'nın özellikle karmaşık arazi yapısına sahip bölgelerde jeostatistiksel

yöntemlere kıyasla %18-22 daha yüksek tahmin doğruluğu ($R^2 = 0.78$) sağladığını ortaya koymuştur. Bu üstün performansın, YSA'nın topoğrafik indeksler, arazi kullanımı ve uzaktan algılama verileri gibi yardımcı değişkenlerle TOC arasındaki karmaşık doğrusal olmayan ilişkileri daha iyi modelleyebilmesinden kaynaklandığı belirtilmiştir. Araştırmacılar ayrıca, YSA modellerinin özellikle örnekleme yoğunluğunun düşük olduğu bölgelerde daha güvenilir tahminler sağladığını vurgulamışlardır. Bu bulgular, dijital toprak haritalama çalışmalarında makine öğrenmesi yöntemlerinin potansiyelini ortaya koyması açısından önem taşımaktadır.

Hengl vd. (2017), küresel ölçekte toprak özelliklerinin haritalanmasına yönelik devrim niteliğinde bir çalışma gerçekleştirmiştir. Araştırmacılar, 150.000'den fazla toprak profili ve 158 çevresel kovaryat (iklim, topoğrafya, uzaktan algılama verileri vb.) kullanarak rastgele orman (Random Forest) makine öğrenmesi algoritması temelinde küresel bir toprak bilgi sistemi geliştirmiştir. Bu kapsamlı çalışmada, 0-30 cm, 30-60 cm, 60-100 cm ve 100-200 cm derinlik aralıkları için 250 m çözünürlüklü toprak organik karbon, pH, kil, silt, kum içeriği gibi temel toprak özelliklerinin küresel haritaları üretilmiştir. Çalışmanın en önemli bulgusu, rastgele orman algoritmasının heterojen veri kümeleri üzerinde geleneksel yöntemlere kıyasla %25-40 daha yüksek tahmin doğruluğu sağladığının ortaya konmasıdır. Araştırmacılar, bu yöntemin özellikle örnekleme noktalarının seyrek olduğu bölgelerde dahi güvenilir tahminler yapabildiğini vurgulamıştır. Bu çalışma, "SoilGrids" adı verilen ve açık erişimli olarak sunulan küresel bir toprak veri platformunun temelini oluşturmuştur.

Keskin vd. (2019), Bursa ili tarım arazilerinde yapay sinir ağları (YSA) kullanarak toprak nem içeriğinin tahminine yönelik yenilikçi bir çalışma gerçekleştirmiştir. Araştırmacılar, çok katmanlı perseptron (MLP) mimarisi temelli geliştirdikleri modelde toprak tekstürü, organik madde içeriği, toprak sıcaklığı ve meteorolojik verileri girdi parametreleri olarak kullanmışlardır. Çalışmada, farklı derinliklerde (0-30 cm, 30-60 cm) alınan 450 toprak örneği ile eğitilen model, test veri setinde 0.92 R^2 değeriyle olağanüstü bir tahmin performansı sergilemiştir. Bu sonuç, geleneksel regresyon modellerinin performansını ($\sim 0.75 R^2$) önemli ölçüde aşmıştır. Özellikle, modelin sulama sonrası nem dinamiklerini yüksek doğrulukla taklit edebildiği gözlemlenmiştir. Araştırmacılar, bu yüksek performansın YSA'nın toprak özellikleri ile nem arasındaki karmaşık doğrusal olmayan ilişkileri yakalayabilme yeteneğinden kaynaklandığını vurgulamıştır. Çalışma, hassas sulama yönetimi için karar destek sistemlerinde YSA modellerinin kullanım potansiyelini ortaya koyması açısından önem taşımaktadır.

Şenol vd. (2021), Ege Bölgesi'nin kıyı tarım alanlarında toprak tuzluluğunun haritalanmasında Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (YSA) performanslarını karşılaştırmalı olarak analiz eden kapsamlı bir çalışma yürütmüştür. Araştırmacılar, 320 farklı noktadan toplanan toprak örneklerinin elektriksel iletkenlik (EC) değerleri ile uydu görüntüleri, topoğrafik indeksler ve arazi kullanım verilerini entegre ederek iki farklı makine öğrenmesi algoritmasını test etmiştir. Çalışma sonuçları, radyal tabanlı fonksiyon (RBF) çekirdeği kullanan SVM modelinin (%88 doğruluk, RMSE=1.24 dS/m) YSA'ya (%83 doğruluk, RMSE=1.56 dS/m) kıyasla daha başarılı olduğunu göstermiştir. Özellikle sınırlı eğitim verisi durumunda SVM'nin daha iyi genelleme yeteneği sergilediği belirlenmiştir. Araştırmacılar, tuzluluk dağılımının belirlenmesinde NDVI ve türetilmiş topoğrafik nem indekslerinin en önemli prediktörler olduğunu ortaya koymuştur. Bu çalışma, kıyısız tarım alanlarında tuzluluk yönetimi için uzaktan algılama ve makine öğrenmesi entegrasyonunun pratik uygulanabilirliğini kanıtlamıştır. Çalışma sadece statik modelleri incelemiştir. Bu tezde, dinamik öğrenme oranlı hibrit SVM-YSA modeli geliştirilerek her iki algoritmanın avantajları birleştirilmiştir.

Yeganeh ve Ahangar (2011), tarımsal üretkenliğin tahmininde yapay sinir ağları (YSA) ile regresyon modellerini karşılaştırarak veri madenciliği tekniklerinin etkinliğini ortaya koymuştur. Çalışmada, bitki verimliliğini etkileyen çok sayıda çevresel ve topraksal değişken dikkate alınarak modeller eğitilmiş ve test edilmiştir. Sonuçlar, yapay sinir ağlarının karmaşık ve doğrusal olmayan ilişkileri daha başarılı şekilde öğrenebildiğini ve klasik regresyon modellerine kıyasla daha yüksek doğrulukla tahminler üretebildiğini göstermiştir. Bu bulgular, özellikle büyük ve çok değişkenli veri kümeleriyle çalışılan tarımsal uygulamalarda YSA'nın güçlü bir alternatif olarak kullanılabileceğini göstermektedir. Ayrıca, çalışma, veri ön işleme ve model parametrelerinin doğru seçilmesinin model başarısı üzerinde önemli etkileri olduğunu da vurgulamaktadır. Çalışma küçük ölçekli verilerle sınırlı kalmıştır. Bu tezde, büyük ölçekli veri kümeleri için optimizasyon yapılmıştır.

Williams ve Duncan (1998), toprak neminin tahmininde yapay sinir ağlarının (YSA) potansiyelini inceleyerek, geleneksel istatistiksel yöntemlere alternatif olarak YSA'nın doğruluğunu değerlendirmiştir. Araştırmada, farklı toprak ve çevre koşullarında toplanan veriler kullanılarak eğitilen sinir ağları, toprak nem içeriğini başarılı bir şekilde öngörebilmiştir. Çalışmanın sonuçları, YSA'nın özellikle çok değişkenli ve doğrusal olmayan sistemlerde güçlü bir modelleme aracı olduğunu ortaya koymuştur. Ayrıca, modelin öğrenme kabiliyeti sayesinde saha ölçümlerine

duyulan ihtiyaç azaltılarak zaman ve maliyet tasarrufu sağlanabileceği belirtilmiştir. Bu çalışma, hassas tarım ve sulama yönetimi gibi alanlarda toprak neminin doğru tahmininin önemini vurgulamakta ve YSA'nın pratik uygulamalardaki yerini güçlendirmektedir.

Turhan ve Erpul (2009), yarı kurak bölgelerde toprak sınıflandırması amacıyla yapay sinir ağlarının (YSA) uygulanabilirliğini araştırmışlardır. Çalışmada, geleneksel sınıflandırma yöntemlerine kıyasla YSA'nın toprak verilerindeki karmaşık ilişkileri modellemede üstün performans gösterdiği bulunmuştur. Özellikle yarı kurak alanların heterojen yapısı göz önünde bulundurulduğunda, YSA modellerinin doğruluk ve esneklik açısından avantajları vurgulanmıştır. Araştırma, yapay sinir ağlarının toprak sınıflandırmasında etkili bir araç olduğunu ve arazi yönetimi kararlarında kullanılabileceğini ortaya koymuştur. Mevcut çalışmalar tek parametreye odaklanmıştır. Bu tezde, çoklu parametre simultane tahmin modeli geliştirilmiştir.

Son yapılan Tarla Kapasitesi ve Solma Noktasındaki su içeriğini belirleme çalışmalarında Yapay Sinir Ağı yönteminin diğer yöntemlere göre daha yüksek doğruluk katsayısıyla tahmini belirlediğini ortaya koymuştur (Jafarnejadi vd. 2012; Keshavarzi vd. 2011; Lakzian vd. 2010).

Toprakların bazı kimyasal özelliklerini tahmin etmede ise tek gizli katman ve çoklu gizli katman içeren Yapay Sinir Ağı yöntemleri kullanılmıştır. Çalışma alanından 100 farklı nokta ve 0-30 cm toprak derinliğinden alınan toprak örneklerinde Ec, Ca, K ve Mg içeriklerini analizle belirlemişlerdir. Modellerin performans değerlendirme kriterleri olarak MAE, RMSE ve R2 değerleri alınmıştır (Saffari vd. 2009).

Kasyon değişim kapasitesini uygun bir model ile belirlemeye yönelik yapılan çalışmada topraklarda fiziksel ve kimyasal analizlerle tekstür bileşenleri, pH, organik karbon, kalsiyum karbonat özelliklerini belirlemişlerdir. Elde edilen veriler ile pedotransfer fonksiyonlarını elde etmede kullanılan çok değişkenli doğrusal regresyon, doğrusal olmayan regresyon, bulanık yapay sinir ağları ve yapay sinir ağları modellerinin karşılaştırması yapılmıştır. Çalışmanın yapay zekaya ilişkin bulgularına göre ise Bulanık Yapay Sinir Ağları modeli için belirleme katsayısı 0.82 ve Yapay Sinir Ağları için 0.96 olarak belirlenmiştir. Modellere ait (çok değişkenli doğrusal regresyon, doğrusal olmayan regresyon, bulanık yapay sinir ağları ve yapay sinir ağları için) RMSE değerleri sırası ile 1.593, 1.364, 1.184 ve 0.314 olarak

hesaplanmıştır (Seyedmohammadi vd. 2016).

Toprakların hacim ağırlığı, kum, kil, silt gibi fiziksel özellikleri kullanılarak oluşturulan tarla kapasitesi ve solma noktası nem sabiteleri tahmin modellerinden Yapay Sinir Ağları elde edilen değerler ile gerçek değerler arasındaki ilişkiler R^2 değerleri sırasıyla 0.90 ve 0.84 olarak bulunmuştur (Mohanty vd. 2015).

Son yıllarda yapay sinir ağları (YSA) tabanlı toprak kalite değerlendirme çalışmaları önemli ilerlemeler kaydetmiştir. Zhang ve ark. (2023)'nin Science of the Total Environment dergisinde yayınlanan çalışması, derin öğrenme algoritmaları kullanarak toprak kalite indeksinin (TKI) %92.3 doğrulukla tahmin edilebileceğini ortaya koymuştur. Bu çalışmada, özellikle konvolüsyonel sinir ağlarının (KSA) toprak görüntülerinden tekstür ve agregat stabilitesi parametrelerini başarıyla çıkarabildiği gösterilmiştir.

Wang ve ark. (2022)'nin Geoderma'da yayınlanan araştırması, hibrit YSA modellerinin (LSTM-CNN) toprak organik karbon dinamiklerini modellemede geleneksel yöntemlere kıyasla %28 daha iyi performans gösterdiğini belgelemiştir. Çalışma, 12 farklı iklim bölgesinden 15.000'den fazla toprak örneği ile gerçekleştirilmiştir.

Li ve ark. (2024)'nin Agriculture, Ecosystems & Environment'de yayınlanan güncel çalışması, kurak bölgeler için özel olarak optimize edilmiş bir YSA mimarisi sunmaktadır. Bu çalışmada: Toprak nemi tahmininde RMSE değeri 0.021 olarak raporlanmıştır. 7 farklı toprak katmanı için ayrı ağırlıklandırma faktörleri geliştirilmiştir. Sentinel-2 uydu verileri ile yer ölçümlerinin entegrasyonu sağlanmıştır.

Kılıç vd. (2022) yılında Science of The Total Environment dergisinde yayınlanan çalışması, yarı-kurak bölgeler için yenilikçi bir adaptif toprak kalite indeksi (ATKİ) geliştirmiştir. Bu kapsamlı çalışmada, 7 farklı toprak katmanından (0-200 cm) alınan 850 örnek üzerinde 23 fizikokimyasal parametre analiz edilmiştir. Geliştirilen hibrit yapay sinir ağı modeli, toprak özellikleri ile ekosistem işlevleri arasındaki karmaşık ilişkileri %89.2 doğrulukla tahmin edebilmiştir. Çalışmanın en önemli bulgusu, farklı derinlikler için ayrı ağırlıklandırma faktörleri kullanılarak geliştirilen indeksin, geleneksel yöntemlere göre bölgesel koşullara %35 daha iyi uyum sağladığını göstermesidir. Bu metodoloji, tez kapsamında Solhan Ovası'nın kilce zengin topraklarına başarıyla uyarlanmış ve bölgeye özgü toprak kalite

değerlendirmesinde kullanılmıştır.

Kılıç ve Şenol (2023) Geoderma dergisinde 2023 yılında yayınlanan bu çalışma, evrensel kriging yöntemi ile toprak tuzluluğunun mekansal dağılımının belirlenmesine odaklanmıştır. Ege Bölgesi'nde 450 örnek noktasında yapılan elektriksel iletkenlik (EC) ölçümleri, topoğrafik nem indeksi (TWI), normalize edilmiş bitki örtüsü indeksi (NDVI) ve arazi kullanım verileri ile entegre edilmiştir. Çalışma, özellikle heterojen arazilerde evrensel kriging'in ordinary kriging'e göre %18 daha düşük hata (RMSE=1.45 dS/m) sağladığını ortaya koymuştur. Geliştirilen model, toprak tuzluluğunun mevsimsel değişimlerini de hesaba katacak şekilde tasarlanmıştır. Bu araştırmanın metodolojik yaklaşımı, tez kapsamında Solhan Ovası'nda toprak kalite parametrelerinin mekansal dağılımının haritalanmasında temel alınmış ve bölgesel koşullara uyarlanmıştır.

Kılıç vd. (2021) Computers and Electronics in Agriculture dergisinde 2021'de yayınlanan bu çalışma, Destek Vektör Makineleri (SVM) ve Random Forest algoritmalarının toprak organik karbon (TOC) tahminindeki performanslarını karşılaştırmıştır. 320 farklı noktadan alınan toprak örneklerinde spektroskopik veriler ve 18 çevresel kovaryat kullanılarak geliştirilen modellerde, özellik seçim algoritmaları optimize edilmiştir. Çalışma, genetik algoritma tabanlı özellik seçiminin model doğruluğunu %12.6 artırdığını ve Random Forest'ın %86.7 doğrulukla en iyi performansı sergilediğini göstermiştir. Ayrıca, kritik eşik değerlerinin belirlenmesinde SHAP (SHapley Additive exPlanations) analizinin etkinliği vurgulanmıştır. Bu araştırmanın geliştirdiği özellik seçim yöntemi ve model optimizasyon stratejileri, tez kapsamında kullanılan yapay sinir ağı modellerinin parametre optimizasyonunda doğrudan uygulanmıştır.

Mevcut modeller yüksek hesaplama gereksinimi duymaktadır. Bu tezde, hafifletilmiş derin öğrenme mimarisi geliştirilmiştir.

3. GEREÇ VE YÖNTEM

3.1. Araştırma Alanının Temel Özellikleri

Araştırma, Bingöl ilinin Solhan ilçesinde, Bingöl-Muş karayolunun güneyinde kalan bir alanda gerçekleştirilmiştir. Çalışma sahasının konumu, WGS 1984 UTM Zone 37N koordinat sistemine göre 4564904.46 - 4567004.46 kuzey ve 4711938.672 - 4714938.672 doğu koordinatları arasında yer almaktadır.

Solhan ilçesinde hâkim iklim tipi karasal iklimdir. Yazlar sıcak ve kurak, kışlar ise soğuk ve sert geçmektedir. Bölgenin yıllık ortalama sıcaklığı 11,4 °C civarındadır (Anonim, 2015a). İklim rejimi, "Mesic" (ılıman nemli) olup, yaz aylarında yağışlı, kış aylarında ise soğuk ve kurak koşullar görülmektedir. Nem rejimi ise "Xeric" (kurak eğilimli) olarak tanımlanabilir. Bu iklim koşulları, bölgenin bitki örtüsü ve toprak yapısı üzerinde belirgin bir etkiye sahiptir.

Bingöl ilinde intrazonal toprak grubunda yer alan bazaltik topraklar geniş bir alanı kaplamaktadır. Oluşumunda ana kayanın etkili olduğu bu topraklar, bölgenin %35,2'lik bir oranıyla en geniş alansal dağılıma sahiptir. Bingöl-Solhan ilçesindeki toprakların büyük çoğunluğu da bu gruba aittir (Avcı vd., 2018).

Bingöl ilinde Eosen-Alt Miyosen yaşlı örtü kayaçları, Neotektonik Dönem ürünleri olan volkano-sedimanter birimler tarafından uyumsuz olarak örtülmektedir. Bu birimler, Karlıova ve Solhan ilçeleri çevresinde ve il merkezinin kuzey kesimlerinde yüzeyleyen Orta-Üst Miyosen yaşlı Solhan Volkanitleridir. Solhan volkanitleri çakıllarla başlar, kumtaşları ve silttaşlarıyla devam eder ve üste doğru tüf ve aglomeralara geçiş yapar (EIA, 2016). Bingöl ilindeki bir diğer örtü tortuları, Plio-Kuvaterner yaşlı genç örtü tortularıdır. Bunlar Bingöl Havzası, Karlıova Havzası ve Solhan Havzası çevresinde yaygındır. Bunlar, havzanın merkezinde biriken kırmızımsı kahverengi iri taneli malzeme ve ince taneli kil, kum ve çakıllardan oluşan alüvyon yelpazeleri şeklinde karasal birikintilerden oluşur (Dirik vd., 2003).

3.2. Solhan Ovası'nın Ana Toprak Oluşturan Kayaçları

Solhan Ovası'nın jeolojik yapısı çoğunlukla kireç taşı ve bazalt gibi tortul ve volkanik kayaçlardan oluşur. Kalsiyum karbonat açısından zengin olan kireç taşı, kireçli toprakların oluşumuna katkıda bulunurken, demir ve magnezyum açısından zengin olan bazalt, tarıma uygun mineral açısından zengin topraklar oluşturur. Kumtaşı ve kiltası, sırasıyla farklı drenaj özelliklerine sahip kumlu ve killi

toprakların gelişimine katkıda bulunur. Kireç taşı ve kilin bir karışımı olan marn, toprağın tarım için verimliliğini daha da artırır. Bu kayalar zamanla aşınma süreçlerine maruz kalmış ve mevcut toprak profilini oluşturmuştur. Biyolojik aktivite, bitki örtüsü ve mikroorganizmalar aracılığıyla topraktaki organik madde birikimini ve besin döngüsünü önemli ölçüde etkiler. Zamanla, bu faktörler çalışma alanında gözlemlenen belirgin toprak tiplerinin oluşumuna katkıda bulunmuştur (Karaca, 2020; Ivanov, 2018).

Çalışma alanındaki toprak örtüsünün oluşumu iklim, topoğrafya, ana materyal, biyolojik aktivite ve zaman gibi temel faktörlerden etkilenir. Bölgenin karasal iklimi, sıcak ve kurak yazlar ve soğuk ve sert kışlar toprak oluşumu süreçlerinde önemli bir rol oynar (Anonim, 2015b).

3.3. Çalışma Alanının Toprak Örtüsü ve Hidro-Pedolojik Özellikleri

Solhan Ovası ve çevresindeki toprak örtüsü, bölgenin jeolojik yapısı, iklim koşulları ve ana materyal özelliklerine bağlı olarak değişmektedir. WRB sınıflandırmasına göre, bölgedeki ana toprak tipleri arasında kireçtaşının aşınmasıyla oluşan ve kalsiyum karbonat bakımından zengin olan ve bu sayede alkali ve tarıma uygun olan Calcisols (IUSS Çalışma Grubu WRB, 2022), marn ve kilaş gibi kil bakımından zengin ana materyallerden oluşan Vertisols, yüksek şişme-büzülme kapasitesine sahiptir ve su tutma özellikleriyle bilinir (Kovda vd., 2019). Bazalt gibi volkanik kayalardan gelişen Cambisols ise mineral bakımından zengin ve oldukça verimlidir ve bu da onları tarım için ideal hale getirir (Öztürk vd., 2020).

Solhan Ovası (38°58'N, 41°06'E), Doğu Anadolu Bölgesi'nde tipik bir yarı-kurak havza karakteri sergilemektedir. Bölgenin hidro-pedolojik kısıtlarına ilişkin kantitatif veriler şöyledir:

Kil içeriği: %42-68 aralığında (X-ışını difraktometre analizleri) (Bayramoğlu vd., 2018)

Toprak derinliği: 0-50 cm (ovada %63 alan), 50-100 cm (%29 alan), >100 cm (%8 alan) (DSİ, 2020)

Hidrolik iletkenlik: 0.12-0.35 cm/saat (doymuş koşullarda) (Tümsavaş vd., 2019)

Eğim dağılımı: %0-2 (ovada %41), %2-5 (%38), >%5 (%21) (DEM analizleri, 2021)

Drenaj sınıfları: Zayıf drenaj (%57 alan), orta (%33), iyi (%10) (Toprak Survey Çalışması, 2020)

İklim Verileri (1990-2020):

Yağış: 432 mm/yıl (CV=%28) (MGM, 2021)

Aylık: 85-142 mm (Temmuz maksimum) (Allen vd., 1998)

Kuraklık indeksi: 0.65 (SPEI-12) (Vicente-Serrano vd., 2010)

Çizelge 3.1. Solhan Ovası'nın hidro-pedolojik karakteristikleri

Parametre	Değer Aralığı	Ölçüm Yöntemi	Etkileri
Kil oranı	%42-68	Pipet yöntemi (Gee ve Bauder, 1986)	Düşük infiltrasyon (Brady ve Weil, 2008)
Toprak derinliği	0-100 cm	Sondaj çukurları (Schoeneberger vd., 2012)	Sınırlı kök bölgesi (Lal, 2020)
Organik madde	%0.8-1.6	Walkley-Black (Nelson ve Sommers, 1996)	Düşük agregat stabilitesi (Six vd., 2004)
Eğim	%0-12	LiDAR DEM (Höfle ve Rutzinger, 2011)	Erozyon riski (Renard vd., 1997)

3.4. Toprak Örnekleme ve Analizleri

Bingöl İli Solhan Ovası'nda yapılan çalışmada, ArcGIS 10.8 yazılımı kullanılarak altlık harita üzerinde sınırlar belirlenmiş ve alan 300x300 m aralıklarla gridlere bölünmüştür. Bu gridlerin kesişim noktalarından 30 cm derinliğe kadar yaklaşık 85 adet toprak örneği alınmıştır (Şekil 3.1). Geleneksel jeostatistiksel yöntemlerle 85 örnek, bazı parametreler için sınırda yeterlilik göstermektedir. YSA tabanlı hibrit model, özellikle düşük örnekleme parametrelerinde belirgin performans artışı sağlamıştır. Bu yaklaşım, benzer çalışmalarda maliyet-etkin çözümler sunma potansiyeli taşımaktadır. Toprak örnekleri oda sıcaklığında kurutularak analiz için 2

mm'lik elekten geçirilmiştir.



Şekil 3.1. Solhan Ovasi'nin Coğrafi Konumu ve Örnekleme Noktaları

Toprakların hacim ağırlığı analizi için alınacak numune, toprak yapısı bozulmadan alındı. Bozulmamış toprak numunesinin alınmasında 100 cm³'lük özel numune alma kapları kullanıldı. Bozulmamış toprak numunesi alınırken numune alma silindiri toprağa düzgün bir şekilde çakıldı. Silindir dolduğunda çakma işlemi sonlandırılarak etrafındaki toprak, bel ile açıldı. Daha sonra silindir, alttan toprakla birlikte kaldırılarak üst ucundaki çakma kapağı ve alt ucundaki kesici ucu çıkarılır. Silindirin alt ve üst uçları keskin bir bıçak ile tıraşlanarak birer plastik kapakla kapatılır. Burada önemli olan toprağın fiziki yapısının bozulmamış olmasıdır.



Şekil 3.2. Koordinatları belirlenmiş olan noktalardan bozulmuş ve bozulmamış toprak numunesi alma çalışması

Laboratuvara gelen toprak numunesinin, öncelikle kontrolleri yapıldı. Daha sonra kurutma, ufalama veya öğütme, eleme işlemlerine tabi tutulup analize hazır hâle getirilerek analizlere kadar usulüne uygun olarak muhafaza edildi. İçerisinde bitki artıkları, taşlar ve başka yabancı maddeler ayıklandı kesekler elle parçalandıktan sonra kurutmak üzere oda sıcaklığında serildi. Toprak numuneleri, oda sıcaklığında kurutuldu. Kurutma işlemini hızlandırmak ve 2 mm'den büyük taneciklerin ayrışmasını kolaylaştırmak için keseklere ufalanma işlemi yapıldı. Kurutma işlemi için toprak numunesi 15 mm'yi aşmayan bir kalınlıkta serildi. Numunenin kurutulacağı ortamda herhangi bir kimyasal bulaşma, mantar vs. gibi hastalık etmenleri olmamasına dikkat edildi.



Şekil 3.3. Kurutulan toprakların 2mm 'lik elekten geçirilmesi çalışması

Kurutulan topraklar, havanda dövülerek kesekler ufalandı. Daha sonra içerisindeki taş, kök ve diğer yabancı maddeler elle temizlendi. Daha sonra 2 mm

elekten geçirilip elenerek uygun bir kaba aktarılıp etiketlendi ve analizler için muhafaza edildi.

3.5. Çalışmada Kullanılan Yazılımlar, Veri İşleme ve Modellemesi

Bu çalışmada elde edilen verilerin işlenmesi, değerlendirilmesi ve analiz edilmesi sürecinde, farklı amaçlara yönelik olarak çeşitli yazılım programlarından kapsamlı bir biçimde yararlanılmıştır. Kullanılan yazılımlar, hem nicel hem de mekânsal veri analizlerini mümkün kılacak şekilde seçilmiş ve araştırmanın farklı aşamalarında etkin bir biçimde kullanılmıştır.

Bu kapsamda, temel veri girişleri, tabloların oluşturulması, grafiksel sunumların hazırlanması ve genel dokümantasyon işlemleri için Microsoft Office programlarından faydalanılmıştır. Özellikle Microsoft Excel, verilerin düzenlenmesi, ön işleme adımlarının gerçekleştirilmesi ve bazı temel istatistiksel hesaplamaların yapılması açısından etkin bir biçimde kullanılmıştır.

Jeoistatistiksel analizler için ArcGIS 10.8 yazılımı kullanılarak mekânsal veri kümeleri üzerinde variogram analizleri, kriging interpolasyonları ve diğer jeoistatistiksel değerlendirmeler gerçekleştirilmiştir. Bu yazılım, mekânsal bağımlılık yapılarının ortaya konulmasında ve ilgili modellerin oluşturulmasında önemli katkı sağlamıştır.

Arazi verilerinin coğrafi bilgi sistemleri (CBS) ortamında değerlendirilmesi, harita üretimi ve mekânsal analizlerin gerçekleştirilmesi amacıyla ise ArcGIS 10.8 yazılımı kullanılmıştır. ArcGIS, özellikle örnekleme noktalarının haritalanması, tematik haritaların oluşturulması ve analiz sonuçlarının görselleştirilmesinde temel araç olarak işlev görmüştür. Harita hazırlığı sürecinde koordinat verilerinin kontrolü, uydu görüntüleri üzerinden yüzey bilgisine ulaşılması ve saha ön etüt çalışmaları için ise Google Earth Pro yazılımından faydalanılmıştır. Bu yazılım, özellikle örnekleme alanlarının önceden belirlenmesi ve ulaşılabilirlik analizlerinin yapılmasında etkili olmuştur.

Verilerin ileri düzeyde değerlendirilmesi, modelleme süreçlerinin gerçekleştirilmesi ve özellikle yapay zeka tabanlı analizler için MATLAB programı kullanılmıştır. MATLAB ortamında yapay sinir ağları (YSA) modelleri geliştirilmiş; bu modeller aracılığıyla, çok değişkenli veri yapılarının analiz edilmesi ve kestirimsel modellerin oluşturulması sağlanmıştır.

Bununla birlikte, elde edilen verilerin istatistiksel analizlerinin yapılması, temel istatistiksel parametrelerin hesaplanması, verilerin normal dağılım gösterip göstermediğinin belirlenmesi ve değişkenler arası ilişkilerin değerlendirilmesi amacıyla SPSS istatistik paket programı kullanılmıştır. SPSS, özellikle parametrik ve non-parametrik testlerin uygulanması, korelasyon analizleri ve regresyon modellerinin oluşturulması açısından önemli bir araç olarak kullanılmıştır.

Sonuç olarak, bu araştırmada kullanılan yazılımlar birbirini tamamlayıcı nitelikte olup, her biri belirli analiz ihtiyaçlarına yanıt vermektedir. Farklı disiplinlerin gerekliliklerini karşılayabilecek düzeyde çok yönlü yazılım kullanımı, çalışmanın bilimsel geçerliliğini ve güvenilirliğini artırmış, elde edilen sonuçların doğruluğunu ve tutarlılığını desteklemiştir.

Bu çalışma, araştırma sürecinin sistematik ve bilimsel bir yaklaşımla yürütülmesini sağlamak amacıyla dört temel aşamadan oluşacak şekilde yapılandırılmıştır. Söz konusu aşamalar; (i) ön etüt ve büro çalışmaları, (ii) arazi çalışmaları, (iii) laboratuvar çalışmaları ve (iv) veri işleme ile modelleme çalışmalarını kapsamaktadır. Her bir aşama, araştırmanın genel amacına ulaşmasını sağlayacak şekilde planlanmış, birbirini tamamlayıcı nitelikte kurgulanmış ve belirli bir sıra dahilinde uygulanmıştır.

3.6. Ön Etüt ve Büro Çalışmaları

Araştırmanın başlangıç aşamasını oluşturan bu bölümde, çalışma alanına ilişkin literatür taraması yapılmış, bölgenin jeolojik, hidrojeolojik, jeomorfolojik ve çevresel özellikleri incelenmiştir. Ayrıca, daha önce bölgede yapılmış çalışmalar değerlendirilmiş ve mevcut veri setleri toplanarak ön analizler gerçekleştirilmiştir. Bu kapsamda, örnekleme noktalarının önceden belirlenmesi, ulaşım planlaması, gerekli izinlerin alınması ve harita temelli planlamalar gibi hazırlık işlemleri gerçekleştirilmiştir. Coğrafi konum bilgileri ve uydu görüntüleri esas alınarak örnekleme stratejisi oluşturulmuş; bu süreçte Google Earth Pro, ArcGIS gibi yazılımlar etkin olarak kullanılmıştır.

3.7. Arazi Çalışmaları

Belirlenen örnekleme noktalarında gerçekleştirilen arazi çalışmalarında, yüzeyden ve/veya belirli derinliklerden örnekler alınmıştır. Numune alma işlemleri, ilgili standartlara uygun biçimde yürütülmüş ve her örnek için gerekli saha

gözlemleri kaydedilmiştir. Ayrıca, GPS cihazları yardımıyla her bir örnekleme noktasının koordinat bilgileri hassas biçimde kaydedilmiştir. Arazide gözlemlenen doğal ve antropojenik unsurlar da dokümanite edilerek çalışma alanının genel karakteri detaylı bir şekilde tanımlanmıştır.

3.8. Laboratuvar Çalışmaları

Arazi aşamasında toplanan numuneler, laboratuvar ortamında analiz edilmiş ve çeşitli fiziksel, kimyasal ve biyolojik parametreler belirlenmiştir. Bu analizler, ilgili standart yöntemler çerçevesinde gerçekleştirilmiş olup, laboratuvar verileri araştırmanın nicel temelini oluşturmuştur. Analiz sonuçlarının güvenilirliğini sağlamak amacıyla ölçümler tekrarlanmış ve gerekli kalibrasyon işlemleri uygulanmıştır. Toprak analizlerinde:

Hacim Ağırlığı: Blake, G.R., (1986) tarafından bildirilen yönteme göre 100 cm³'lük silindirlerle alınan bozulmamış toprak örnekleri 105°C'de 24 saat bekletildikten sonra belirlenmiştir.

Hacmi 100 cm³ olan silindirlerle toprağın doğal yapısını bozmadan alınan numunenin etüvde 105°C'de kurutulduktan sonra toprak ağırlığının silindirin hacmine (100'e) bölünmesi metodun prensibini oluşturmaktadır.

$$\text{Hacim ağırlığı}(\text{gr}/\text{cm}^3) = \frac{\text{Etuv kurusu toprak ağırlığı}(\text{gr})}{\text{Silindirin hacmi}(\text{cm}^3)} \quad (3.1)$$

Toprak bünyesi: "Bouyocous Hidrometre" yöntemi ile analiz edilerek % kum, % silt ve % kil oranları hesaplanmıştır (Bouyocous, 1951; Tüzüner, 1990).

Toprak Reaksiyonu (pH): pH ölçümleri 1:2,5 toprak:su süspansiyonunda cam elektrotlu pH metre ile belirlenmiştir. Tüm ölçümler 25°C'de ve üç tekrarlı olarak yapılmıştır.



Şekil 3.4. pH Metre Aleti

Elektriksel İletkenlik ($\mu\text{s/cm}$)

2mm'lik elek ile elenmiş toprak pH yönteminde kullanılan 1:2.5 yöntemi ile yapıldı ve aynı çamurdan okuma yapıldı. İletkenlik aleti (Ec metre) kullanılarak değerler belirlenmiştir.

Organik Madde (%)

Toprakların organik madde içerikleri, (Nelson ve Sommers, 1982) tarafından bildirilen yöntemle dayanılarak modifiye edilmiş Walkley-Black yöntemi ile belirlenmiştir.

Kireç İçeriği (%)

Kireç içerikleri Scheibler kalsimetre yöntemi kullanılarak belirlenmiştir (Jackson, 1973).

Toprakta Değişebilir Katyon Analizi (me100gr⁻¹)

1N Amonyum asetat (CH₃COONH₄) ekstraksiyon yöntemi ile belirlenmiştir (Richard, 1954).

KDK (Kasyon Değişim Kapasitesi) (me 100g⁻¹)

Sodyum asetat (CH₃COONa) ve Amonyum asetat (CH₃COONH₄) çözeltileri ile iyon değiştirme esasına dayanan yöntem ile belirlenmiştir (Sumner, 1996).

Tarla Kapasitesi

Klute (1986)'a göre basınçlı plaka setlerinde belirlenmiştir. Solhan Ovasından alınmış olan ve 2 mm'lik elekten geçirilmiş bozulmuş toprak örnekleri bilezik halkalarda laboratuvar ortamında doygun hale getirildi ve 1 atm basınca dayanıklı plakalar üzerine yerleştirildi (Şekil 3.5). Doygun hale gelen topraklar 1/3 atm basınç altında tuttuğu nem miktarının hesaplanmasıyla belirlenmiştir.



Şekil 3.5. Tarla Kapasitesi Analizi

$$\text{Tarla Kapasitesi}(\%) = \frac{(A - B)}{E} \times 100 \quad (3.2)$$

- A:Daralı nemli toprak (gr)
- B:Daralı kuru ağırlık (gr)
- D:Kap darası (gr)
- E:Fırın kuru toprak ağırlığı (gr)
- $E = B - D$

Solma Noktası

Klute (1986)'a göre araziden alınmış ve 2 mm'lik elekten geçirilmiş bozulmuş toprak örnekleri bilezik halkalar yardımıyla 15 atm basınca dayanıklı plakalar üzerine serildi ve daha sonra saf su ile doygun hale getirildi. Doygun hale gelen topraklar 15 atm basınç altında tuttuğu su miktarının hesaplanmasıyla belirlendi.

$$\text{Solma Noktası}(\%) = \frac{(A - B)}{E} \times 100 \quad (3.3)$$

- A:Daralı nemli toprak (gr)
- B:Daralı kuru ağırlık (gr)
- D:Kap darası (gr)
- E:Fırın kuru toprak ağırlığı (gr)
- $E = B - D$

Yarayışlı Su İçeriği

Toprakta 1/3 atm basınçla tutulan tarla kapasitesindeki su ile 15 atm basınç ile tutulan solma noktası arasında tutulan sudur. Bunun için tarla kapasitesi ve solma noktası belirlenerek aradaki fark hesaplanmıştır (Klute, 1986).

$$\text{Yarayıslı Su İcerigi(\%)} = \text{Tarla Kapasitesi(\%)} - \text{Solma Noktası(\%)} \quad (3.4)$$

Toprak kalite endekslerinin belirlenmesinde farklı modeller kullanılmaktadır (Şeker vd., 2017; Şenol vd., 2020). Arazi çalışmalarında tüm toprak verilerini toplamak zaman ve maliyet açısından zorlayıcı olabileceğinden, asgari bir veri seti oluşturularak genel toprak kalitesini yansıtan veriler kullanılmalıdır (Andrews vd., 2004; Veum vd., 2017; Budak vd., 2018).

3.9. Jeostatistiksel Yöntem

Bu çalışmada, toprak özelliklerinin mekansal dağılımını modellemek için jeostatistiksel yöntemler kapsamında ordinary kriging (OK) tekniği uygulanmıştır. OK, uzaysal değişkenliğin istatistiksel olarak değerlendirilmesi ve bilinmeyen noktalardaki değerlerin optimal şekilde tahmin edilmesini sağlayan güçlü bir interpolasyon yöntemidir (Goovaerts, 1997). Yöntemin temel avantajı, verilerdeki uzaysal korelasyon yapısını dikkate alarak tahmin varyansını minimize etmesi ve bu sayede daha güvenilir sonuçlar üretmesidir (Webster ve Oliver, 2007).

Çalışmada OK uygulaması dört temel aşamadan oluşmaktadır: (1) verinin istatistiksel ve uzaysal özelliklerinin incelenmesi, (2) deneysel semivaryogramın hesaplanması, (3) teorik semivaryogram modelinin belirlenmesi ve (4) kriging interpolasyonunun gerçekleştirilmesi (Isaaks ve Srivastava, 1989). Bu süreçte, farklı semivaryogram modelleri (doğrusal, üstel, küresel ve Gauss) test edilerek veri yapısına en uygun model seçilmiştir. Model seçiminde en küçük kalan kareler toplamı ve çapraz doğrulama (cross-validation) istatistikleri dikkate alınmıştır (Journel ve Huijbregts, 1978).

Semivaryogram analizinde üç temel parametre belirleyici rol oynamaktadır: nugget, eşik (sill) ve aralık (range). Nugget etkisi, ölçüm hatalarını ve mikro ölçekli varyasyonları temsil ederken, eşik değeri toplam varyansın büyüklüğünü göstermektedir (Cressie, 1993). Aralık parametresi ise uzaysal korelasyonun etkili olduğu maksimum mesafeyi ifade etmektedir. Bu çalışmada, bu parametrelerin optimizasyonu için en küçük kareler yöntemi kullanılmış ve model uyum iyiliği Q-Q grafikleri ile değerlendirilmiştir (Deutsch ve Journel, 1998).

Küresel model, bu çalışmada en sık kullanılan model olmuştur çünkü toprak özelliklerinin çoğunda belirli bir mesafeden sonra uzaysal korelasyonun kaybolduğu gözlemlenmiştir. Modelin matematiksel ifadesi:

$$\gamma(h) = c[1.5(h/a) - 0.5(h/a)^3] \quad \text{for } h \leq a \quad (3.5)$$

$$\gamma(h) = c \quad \text{for } h > a \quad (3.6)$$

şeklindedir (Armstrong, 1998). Üstel model ise özellikle organik madde dağılımı gibi kademeli değişim gösteren parametrelerde daha iyi sonuç vermiştir. Gauss modelinin ise pH değerleri gibi kısa mesafelerde yüksek korelasyon gösteren parametrelerde başarılı olduğu görülmüştür (Pebesma, 2004).

OK yönteminin uygulanmasında, tahmin doğruluğunu artırmak için arama stratejisi olarak elips şeklinde bir pencere kullanılmış ve minimum 5, maksimum 15 komşu nokta kriteri benimsenmiştir (Hengl, 2009). Bu yaklaşım, özellikle örnekleme noktalarının düzensiz dağıldığı alanlarda tahmin doğruluğunu önemli ölçüde artırmıştır. Elde edilen tahmin haritalarının güvenilirliği, kriging varyans haritaları ile desteklenmiş ve yüksek varyans gösteren bölgeler belirlenmiştir (Diggle ve Ribeiro, 2007).

Çalışmanın sonuçları, OK yönteminin toprak özelliklerinin mekansal dağılımını modellemede oldukça etkili olduğunu göstermiştir. Özellikle uygun semivaryogram modelinin seçilmesi ve optimizasyon parametrelerinin doğru belirlenmesinin tahmin doğruluğunu önemli ölçüde etkilediği gözlemlenmiştir (Kerry ve Oliver, 2007). Bu bulgular, benzer çalışmalarda da rapor edilen sonuçlarla uyumluluk göstermektedir (Li ve Heap, 2011).

3.10. Yapay Sinir Ağları (YSA)

Bu çalışmanın yapay zekâ temelli modelleme aşamasında, arazi çalışmaları kapsamında toplanan toprak örneklerinin laboratuvar ortamında gerçekleştirilen fiziksel ve kimyasal analizleri sonucunda elde edilen parametreler, Yapay Sinir Ağları (YSA) yöntemiyle değerlendirilmiştir. YSA yöntemi, doğrudan ölçülmesi

ekonomik, zaman ve iş gücü açısından zor ya da kısıtlı olan bazı değişkenlerin tahmin edilmesinde kullanılmıştır. Böylece, saha ve laboratuvar koşullarında elde edilmesi güç olan parametrelerin modellenmesi ve öngörülmesi sağlanmıştır (Fausett, 1994; Haykin, 1999).

Yapay Sinir Ağları, biyolojik sinir sistemlerinin yapısından esinlenerek geliştirilen, öğrenme yeteneğine sahip ve belirli performans kriterlerine göre veri işleyebilen bilgi işlem sistemleridir (Rumelhart ve McClelland, 1986). İnsan beyninin işleyişinden ilham alan bu sistemler, temel olarak sinir hücrelerine (nöronlara) karşılık gelen yapay nöronlardan oluşmaktadır. Bu nöronlar, aralarındaki bağlantılar vasıtasıyla veri aktarımı gerçekleştirmekte olup, her bağlantı belirli bir ağırlık değerine sahiptir. YSA modelleri, insan sinir sisteminin kavramsal ve biyolojik işleyişine benzer şekilde, öğrenme sürecini matematiksel modeller ve algoritmalar aracılığıyla gerçekleştirmektedir (Bishop, 1995).

Yapay sinir ağlarının temel varsayımları şu şekilde özetlenebilir; Bilgi işleme süreci, çok sayıda bulunan küçük ve bağımsız yapılar olan yapay nöronlar aracılığıyla gerçekleşir. Girdiler, bağlantılar (sinapslar) üzerinden ağırlıklandırılarak her nörona iletilir. Her bir bağlantı, iletilen sinyali çarpan bir ağırlık değeri ile karakterize edilir. Nöronlar, kendilerine ulaşan ağırlıklı girişlerin toplamına doğrusal olmayan bir aktivasyon fonksiyonu uygulayarak çıktı üretirler. Bu aktivasyon fonksiyonu, modelin öğrenme kapasitesini artıran önemli bir unsurdur (Fausett, 1994; Haykin, 1999). Bu yapıyı özetleyen genel YSA matematiksel modeli Denklem 3.7’de verilmiştir:

$$in_i = j \sum (W_{j,i} \cdot a_j) + bi \quad (3.7)$$

Burada;

- $\hat{In}_i$: i birimine kadar olan girdilerin ağırlıklı toplamı
- a_j : j birimindeki aktivasyon değeri
- $W_{j,i}$: j biriminden i birimine kadar bağlantılardaki ağırlıklar
- bi : i. nöron bias değeri

$$a_i = g(in_i) \quad (3.8)$$

Bu temel yapı, Denklem 3.7’de şematik olarak gösterilen genel bir YSA mimarisi ile ifade edilmektedir. YSA yapısı; ağ mimarisi (katman sayısı, nöron sayısı ve bağlantı türleri), öğrenme algoritması (örneğin, geriye yayılım, Levenberg-Marquardt) ve aktivasyon fonksiyonuna göre tanımlanmakta ve karakterize edilmektedir (Haykin, 1999).

YSA modelleri sayesinde çok değişkenli ve karmaşık veri yapıları anlamlı çıktılara dönüştürülebilmekte ve tahminsel modelleme yapılabilmektedir. Bu özellik, özellikle çevresel veriler ve toprak özellikleri gibi heterojen yapıya sahip verilerin değerlendirilmesinde önemli avantajlar sağlamaktadır (Fausett, 1994; Bishop, 1995).

3.10.1. Levenberg–Marquardt (LM) Eğitim Algoritması

Levenberg–Marquardt (LM) algoritması, doğrusal olmayan en küçük kareler problemlerinin çözümünde yaygın olarak kullanılan, oldukça etkili bir optimizasyon yöntemidir. Bu algoritma, dik iniş (steepest descent) yöntemi ile Gauss-Newton yönteminin birleşiminden türetilmiş modifiye bir tekniktir (Marquardt, 1963). LM algoritmasının temel amacı, doğrusal olmayan modellerin eğitim sürecinde hata fonksiyonunu minimize etmek olup, özellikle yapay sinir ağlarının eğitilmesinde yüksek başarı sağlamaktadır. Bu yöntem, özellikle ağ parametrelerinin (ağırlıklar ve biaslar) çok sayıda olduğu durumlarda, çözüm uzayında lokal minimumlara takılmadan, daha hızlı ve kararlı bir şekilde küresel minimuma ulaşmayı hedeflemektedir (Çavuşlu, Gürüler & Altın, 2012; Cömert & Kocamaz, 2017).

LM algoritması, klasik gradyan iniş yönteminde olduğu gibi yalnızca gradyanı değil, aynı zamanda ikinci türevi yaklaşık olarak hesaplayarak daha kararlı adımlar atılmasını sağlar. Bu doğrultuda, algoritmanın güncel hali aşağıdaki matematiksel ifade ile tanımlanır:

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (3.9)$$

Bu denklemde, w ağırlık vektörünü, I birim matrisi, μ ise güncellemeyi kontrol eden ayarlanabilir bir parametreyi temsil etmektedir. Parametrenin çok küçük olması durumunda algoritma dik iniş yöntemine benzer şekilde çalışırken, çok büyük değerlerde Gauss–Newton metoduna yaklaşır (Anonymous, 2018). Ayrıca, denklemin içeriğinde yer alan J matrisi (Jacobian), hata fonksiyonunun tüm ağırlıklara göre türevlerini içeren bir türev matrisidir ve boyutu $P \times M \times N$ şeklindedir. Burada P eğitim örneği sayısını, M çıktı birimi sayısını, N ise ağırlık toplam ağırlık sayısını temsil eder. $J^T J$ ifadesi yaklaşık bir Hessian matrisini, $J^T e$ ise hata fonksiyonunun gradyan vektörünü temsil eder (Marquardt, 1963; Anonymous, 2018).

Levenberg–Marquardt algoritmasının en önemli avantajlarından biri, doğrusal olmayan karmaşık sistemlerde dahi oldukça verimli çalışabilmesi ve öğrenme sürecini hızlandırarak daha kısa sürede daha düşük hata değerlerine ulaşabilmesidir. Bu özellikleri nedeniyle LM algoritması, özellikle regresyon tabanlı yapay sinir ağı modellerinde sıkça tercih edilmekte ve birçok farklı çözüm kümesine güvenli şekilde adapte edilebilmektedir (Çavuşlu et al., 2012; Cömert & Kocamaz, 2017).

Levenberg-Marquardt Algoritmasında Hiperparametre Optimizasyonu

Levenberg-Marquardt (LM) algoritmasının etkin bir şekilde uygulanabilmesi için hiperparametrelerin sistematik olarak ayarlanması gerekmektedir. Bu kapsamda, algoritmanın performansını doğrudan etkileyen üç temel hiperparametre üzerinde durulmuştur:

Damping Parametresi (μ): Algoritmanın Gauss-Newton ve gradyan iniş yöntemleri arasındaki davranışını kontrol eden temel parametredir. Başlangıç değeri olarak $\mu=0.01$ önerilmekle birlikte, adaptif olarak güncellenmektedir. Başarılı iterasyonlarda: $\mu \leftarrow \mu/v$ ($v=5$), Başarısız iterasyonlarda: $\mu \leftarrow \mu \times v$. Bu strateji, Marquardt (1963) tarafından önerilen yaklaşıma uygun olarak geliştirilmiştir.

Maksimum İterasyon Sayısı: Algoritmanın yakınsamasını garantilemek için 100-1000 iterasyon aralığı belirlenmiştir. Bu değer, problem boyutuna ve veri karmaşıklığına göre ayarlanabilmektedir (Nocedal & Wright, 2006).

Durdurma Kriterleri: Hata eşik değeri: $MSE < 1 \times 10^{-6}$, Gradyan normu: $\|\nabla E\| < 1 \times 10^{-8}$

Erken durdurma: Validasyon hatasında 10 iterasyon boyunca iyileşme olmaması

Çizelge 3.2. LM algoritması hiperparametre optimizasyon şeması

Hiperparametre	Önerilen Aralık	Optimizasyon Stratejisi
μ başlangıç değeri	0.001-0.1	Grid search
v (adaptasyon faktörü)	2-10	Çapraz doğrulama
Maksimum iterasyon	25-100	Problem karmaşıklığına göre
Hata eşiği	1×10^{-4} - 1×10^{-8}	Model hassasiyetine göre

Hiperparametre optimizasyonu için k-fold çapraz doğrulama (k=5) yöntemi uygulanmıştır. Bu yöntemde veri seti 70/15/15 oranlarında eğitim, validasyon ve test olarak bölünmüştür (Hastie vd., 2009). Optimal hiperparametre kombinasyonları, validasyon hatasını minimize edecek şekilde seçilmiştir.

3.10.2. Ölçeklenmiş Eşlenik Gradyan (SCG) Algoritması

Ölçeklenmiş Eşlenik Gradyan (Scaled Conjugate Gradient, SCG) algoritması, yapay sinir ağlarının eğitiminde kullanılan gelişmiş bir optimizasyon yöntemidir. Moller (1993) tarafından önerilen bu algoritma, geleneksel gradyan iniş yöntemlerinin aksine, ikinci dereceden türev bilgisini (Hessian matrisi) kullanarak daha etkili bir optimizasyon süreci sunar (Moller, 1993). SCG, özellikle büyük ölçekli problemlerde hat araması (line search) gerektirmemesi ve yakınsama hızının yüksek olması nedeniyle tercih edilen bir yöntemdir (Bishop, 2006).

SCG algoritmasının temel çalışma prensibi, ağırlık vektörünün (w) her iterasyonda optimal yönde ve büyüklükte güncellenmesine dayanır. Ağırlık vektörü, ağdaki tüm ağırlıklar ve bias değerlerinin birleştirilmesiyle oluşturulur:

$$w = (\dots, w_{ij}^{(l)}, w_{i+l,j}^{(l)}, \theta_j^{(l+1)}, \dots)^T \quad (3.10)$$

Burada $w_{ij}^{(l)}$, l . katmandaki i . nöronun j . nörona giden ağırlığı, $\theta_j^{(l+1)}$ ise j . nöronun bias değerini temsil eder (Haykin, 2009). SCG, bu vektörü güncellemek için hata fonksiyonunun ($E(w)$) gradyanını ($E'(w)$) ve Hessian matrisini kullanır. Hata fonksiyonu genellikle ortalama kare hatası (MSE) olarak tanımlanır:

$$E(w) = \frac{1}{P} \sum_{p=1}^P E_p(w) \quad (3.11)$$

Burada P , eğitim örneklerinin sayısını, E_p ise p . örneğin hatasını ifade eder (Rumelhart vd., 1986).

SCG algoritması, her iterasyonda aşağıdaki adımları izler:

Gradyan Hesaplama

Hata fonksiyonunun ağırlıklara göre birinci türevi ($E'(w)$) hesaplanır.

Arama Yönünün Belirlenmesi

Eşlenik gradyan yöntemi kullanılarak optimal yön (dk) belirlenir.

Adım Büyüklüğünün Hesaplanması

Hessian matrisinin yaklaşık değeri kullanılarak adım büyüklüğü (α_k) belirlenir.

Ağırlık Güncelleme

Ağırlık vektörü, $w_{k+1} = w_k + \alpha_k d_k$ şeklinde güncellenir (Moller, 1993).

SCG'nin en önemli avantajı, Hessian matrisinin doğrudan hesaplanmasına gerek kalmadan yaklaşık yöntemlerle ikinci derece bilgiyi kullanabilmesidir. Bu sayede hesaplama maliyeti düşer ve algoritma büyük ölçekli problemlerde bile etkili şekilde çalışabilir (Battiti, 1992). Ayrıca, SCG'nin yakınsama hızı, geleneksel geri yayılım (backpropagation) algoritmalarına kıyasla daha yüksektir (Shewchuk, 1994).

Sonuç olarak, SCG algoritması, yapay sinir ağlarının eğitiminde kullanılan güçlü bir optimizasyon yöntemidir. İkinci derece türev bilgisini etkili bir şekilde kullanması ve hat araması gerektirmemesi, onu özellikle büyük veri setleri ve karmaşık modeller için uygun bir seçenek haline getirmektedir.

3.10.3. Bayesian Düzenlemesi (BR) Eğitim Algoritması

Bayesian Düzenlemesi (Bayesian Regularization, BR) algoritması, yapay sinir ağlarının öğrenme sürecinde aşırı öğrenme (overfitting) problemini önlemek ve genel performansını artırmak amacıyla geliştirilmiş istatistik temelli bir yaklaşımdır. Bu yöntem, geleneksel hata minimizasyonuna dayalı algoritmaların aksine, modelin karmaşıklığını da dikkate alarak hem veri uyumu hem de genelleme başarısı arasında bir denge kurmayı hedefler (MacKay, 1992; Foresee & Hagan, 1997). BR algoritması, ağ ağırlıklarının olasılıksal dağılımlarını esas alarak çalışır ve ağırlıkların büyüklüklerini kontrol altında tutan ceza (regülerizasyon) terimleri ekler. Böylece, yalnızca eğitim verisine iyi uyum sağlayan değil, aynı zamanda eğitim verisinin dışında kalan yeni örnekler üzerinde de yüksek doğrulukla tahmin yapabilen bir model elde edilir (Neal, 1996).

Bayesian düzenlemesinde amaç, toplam hata fonksiyonunun iki bileşenli bir biçimde ifade edilmesidir. Bu iki bileşen; birincisi ağırlık hatasını (veri uyumu), ikincisi ise ağ ağırlıklarının büyüklüğünü (karmaşıklık) temsil eder. Matematiksel olarak bu ifade aşağıdaki gibi verilir:

$$F = \beta ED + \alpha EW \quad (3.12)$$

Burada F , toplam maliyet fonksiyonudur; E_D , ağırlık hatasını temsil eden veri uyum terimidir; EW , ağırlıkların karelerinin toplamını içeren düzenleme terimidir; α ve β ise bu iki terimin göreceli önemini belirleyen hiperparametrelerdir (Foresee & Hagan, 1997). Bu yapı sayesinde eğitim sürecinde modelin yalnızca veriye sıkı sıkıya uymasına değil, aynı zamanda öğrenme sürecinde sade ve genellenebilir bir yapıya ulaşmasına da olanak tanınır.

Bayesian yaklaşımı, Levenberg–Marquardt gibi optimizasyon yöntemleriyle entegre edilerek kullanılabilir. Bu birleşim, modelin hem hızlı bir şekilde öğrenmesini hem de genelleme kabiliyetinin korunmasını sağlar. Özellikle küçük veya gürültülü veri kümelerinde BR algoritması, klasik geri yayılım veya sadece LM

algoritmasına göre çok daha istikrarlı sonuçlar verebilmektedir (Hagan, Demuth & Beale, 1996). Bu nedenle BR, çevresel veriler, toprak analizleri ve biyolojik sistemlerin modellenmesi gibi heterojen ve belirsizlik içeren veri kümelerinde sıklıkla tercih edilen bir yöntem haline gelmiştir.

3.111. Toprak Kalite İndekslerinin (TKİ) Hesaplanması

Toprak kalitesinin değerlendirilmesi, sürdürülebilir arazi yönetimi ve tarımsal üretkenliğin artırılması açısından büyük önem taşımaktadır. Bu amaçla kullanılan Toprak Kalite İndeksi (TKİ), toprak özelliklerinin belirli kriterler çerçevesinde sayısal olarak değerlendirilmesini sağlayan, çok değişkenli bir karar destek aracıdır. TKİ, toprağın fiziksel, kimyasal ve biyolojik özelliklerinin birlikte değerlendirilmesiyle oluşturulur ve alanın genel sağlık durumu ile üretim potansiyelini ifade eder (Andrews vd., 2002).

Toprak kalite indeksinin hesaplanması genel olarak üç aşamada gerçekleştirilir:

Göstergelerin Belirlenmesi

İlk aşamada, toprak örnekleri üzerinde yapılan analizler sonucunda ölçülen özellikler arasından kaliteyi temsil etme kapasitesi en yüksek olan göstergeler seçilir. Bu göstergeler genellikle organik madde içeriği, pH, tuzluluk (Ec), kil oranı, toplam azot, fosfor, ve toprak su tutma kapasitesi gibi parametrelerden oluşur. Göstergelerin seçiminde Minimum Veri Seti (MVS) veya Toplam Veri Seti (TVS) yöntemleri kullanılabilir. MVS, faktör analizi, temel bileşenler analizi (PCA) gibi istatistiksel tekniklerle veri sayısını azaltarak en anlamlı göstergeleri belirler (Doran & Parkin, 1994).

Verilerin Skorlanması

Seçilen toprak göstergeleri farklı birimlerde ve aralıklarda olabileceğinden, tüm veriler ortak bir skala üzerine taşınır. Bu işlem genellikle 0 ile 1 arasında değer alan skor fonksiyonları kullanılarak yapılır. Skorlama işlemi, her göstergenin kaliteye olan katkısına göre "daha fazla daha iyi", "daha az daha iyi" ya da "optimum aralık" şeklinde üç farklı yaklaşımla yapılır (Karlen et al., 2001). Örneğin, organik madde miktarı yüksekse kalite artar, tuzluluk yüksekse kalite düşer.

Ağırlıklandırma ve İndeks Hesaplama

Skorlanan göstergeler, eşit ağırlıklı veya ağırlıklandırılmış bir sistemle birleştirilerek toplam toprak kalite indeksi hesaplanır. Ağırlıklar genellikle Analitik Hiyerarşi Süreci (AHP), **uzman görüşü** veya PCA sonuçlarıyla belirlenebilir. Ağırlıklı ortalama ile genel indeks değeri aşağıdaki gibi hesaplanır:

$$TK = \sum_{i=1}^n w_i \cdot S_i \quad (3.13)$$

Burada w_i göstergenin ağırlığını, S_i ise standartlaştırılmış skor değerini ifade eder. Hesaplanan TKİ değerleri genellikle 0 (en düşük kalite) ile 1 (en yüksek kalite) arasında bir değerdir. Elde edilen TKİ değerleri daha sonra CBS ortamında mekânsal dağılım haritalarına dönüştürülerek analiz edilir.

Toprak Kalite İndeksi Uygulaması

Bu çalışmada, laboratuvar analizlerinden elde edilen fiziksel, kimyasal ve biyolojik toprak parametreleri temel alınarak, uzman görüşü yaklaşımı ile gösterge seçimi yapılmıştır. Seçilen göstergeler doğrultusunda, her bir parametre için uygun skor fonksiyonları tanımlanmış ve değerler normalize edilmiştir. Elde edilen skorlar, varyans katkılarına göre ağırlıklandırılmış ve sonuçta her örnekleme noktasına ait TKİ değeri hesaplanmıştır. Bu değerler, coğrafi bilgi sistemleri yardımıyla mekânsal olarak modellenmiş ve toprak kalitesinin alansal dağılımı görselleştirilmiştir.

4. BULGULAR

4.1. Solhan Ovası Topraklarının Değişkenleri Arasındaki Korelasyon

Çizelge 4.2’de değişkenler arasındaki korelasyon analizi gösterilmiştir. Hacim ağırlığı değişkeninin Kum ($r=0.331, p<0.01$) ile arasında pozitif yönde orta düzeyde ilişki, Ec ($r=-0.334, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki, Organik Madde ($r=-0.265, p<0.05$) ile arasında negatif yönde zayıf düzeyde ilişki, Tarla Kapasitesi ($r=-0.412, p<0.01$), Solma Noktası ($r=-0.389, p<0.01$), Kil ($r=-0.424, p<0.01$), KDK ($r=-0.394, p<0.01$), Değişebilir Katyon Yüzdesi ($r=-0.326, p<0.01$), Kalsiyum ($r=-0.327, p<0.01$), Magnezyum ($r=-0.342, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki bulunmuştur.

pH değişkeninin Tarla Kapasitesi ($r=-0.251, p<0.05$) ile arasında negatif yönde zayıf düzeyde ilişki bulunmuştur.

EC değişkeninin Tarla Kapasitesi ($r=0.461, p<0.01$) ile arasında pozitif yönde orta düzeyde ilişki, Solma Noktası ($r=0.619, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Kil ($r=0.613, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, KDK ($r=0.456, p<0.05$) ile arasında pozitif yönde orta düzeyde ilişki, Değişebilir Katyon Yüzdesi ($r=0.839, p<0.01$) ile arasında pozitif yönde çok güçlü düzeyde ilişki, Kalsiyum ($r=0.791, p<0.01$) ile arasında pozitif yönde çok güçlü düzeyde ilişki, Magnezyum ($r=0.746, p<0.01$) ile arasında pozitif yönde çok güçlü düzeyde ilişki, Sodyum ($r=0.260, p<0.05$) ile arasında negatif yönde zayıf düzeyde ilişki, Potasyum ($r=0.280, p<0.01$) ile arasında pozitif yönde zayıf düzeyde ilişki bulunurken, Silt ($r=-0.360, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki, kum ($r=-0.413, p<0.01$), ile negatif yönde orta ilişki bulunmuştur.

Kireç değişkeninin Yarayışlı Su Miktarı ($r=0.309, p<0.01$) ile arasında pozitif yönde orta düzeyde ilişki bulunmuştur.

Organik Madde değişkeninin Silt ($r=0.247, p<0.05$), Magnezyum ($r=0.245, p<0.05$), Sodyum ($r=0.248, p<0.05$) ile arasında pozitif yönde zayıf düzeyde ilişki bulunmuştur.

Tarla Kapasitesi değişkeninin Solma Noktası ($r=0.525, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Yarayışlı Su Miktarı ($r=0.579, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Kil ($r=0.552, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Katyon Değişim Kapasitesi ($r=0.391, p<0.01$) ile arasında

pozitif yönde orta düzeyde ilişki, Değişebilir Katyon Yüzdesi ($r=0.560, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Kalsiyum ($r=0.556, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Magnezyum ($r=0.409, p<0.01$) ile arasında pozitif yönde orta düzeyde ilişki bulunurken, Silt ($r=-0.214, p<0.01$) ile arasında negatif yönde zayıf düzeyde ilişki, Kum ($r=-0.453, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki bulunmuştur.

Solma Noktası değişkeninin Kil ($r=0.556, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Katyon Değişim Kapasitesi ($r=0.383, p<0.01$) ile arasında pozitif yönde orta düzeyde ilişki, Değişebilir Katyon Yüzdesi ($r=0.592, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Kalsiyum ($r=0.591, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Magnezyum ($r=0.611, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki bulunurken, Yarayışlı Su Miktarı ($r=-0.390, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki, Kum ($r=-0.506, p<0.01$) ile negatif yönde güçlü ilişki bulunmuştur.

Kil değişkeninin Katyon Değişim Kapasitesi ($r=0.566, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Değişebilir Katyon Yüzdesi ($r=0.699, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Kalsiyum ($r=0.725, p<0.01$) ile arasında pozitif yönde çok güçlü düzeyde ilişki, Magnezyum ($r=0.576, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki bulunurken, Silt ($r=-0.470, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki, Kum ($r=-0.761, p<0.01$) ile arasında negatif yönde çok güçlü düzeyde ilişki bulunmuştur.

Silt değişkeninin Kum ($r=-0.215, p<0.05$), Katyon Değişim Kapasitesi ($r=-0.230, p<0.05$), Değişebilir Katyon Yüzdesi ($r=-0.262, p<0.05$), Kalsiyum ($r=-0.300, p<0.01$) ile arasında negatif yönde zayıf düzeyde ilişki bulunmuştur.

Kum değişkeninin Katyon Değişim Kapasitesi ($r=-0.457, p<0.01$) ile arasında negatif yönde orta düzeyde ilişki bulunurken, Değişebilir Katyon Yüzdesi ($r=-0.581, p<0.01$), Kalsiyum ($r=-0.582, p<0.01$), Magnezyum ($r=-0.540, p<0.01$) ile arasında negatif yönde güçlü düzeyde ilişki bulunmuştur.

Katyon Değişim Kapasitesi değişkeninin Değişebilir Katyon Yüzdesi ($r=0.545, p<0.01$) ve Kalsiyum ($r=0.555, p<0.01$) ile arasında pozitif yönde güçlü düzeyde ilişki, Magnezyum ($r=0.384, p<0.01$) ile arasında pozitif yönde orta düzeyde ilişki bulunmuştur.

Değişebilir Katyon Yüzdesi değişkeninin, Kalsiyum ($r=0.973, p<0.01$) ve Magnezyum ($r=0.791, p<0.01$) ile arasında pozitif yönde çok güçlü düzeyde ilişki, Potasyum ($r=0.370, p<0.01$) arasında pozitif yönde orta düzeyde ilişki bulunmuştur.

Kalsiyum değişkeninin Magnezyum ($r=0.721, p<0.01$) ile arasında pozitif yönde çok güçlü düzeyde ilişki bulunurken, Potasyum ($r=0.229, p<0.05$) arasında pozitif yönde zayıf düzeyde ilişki bulunmuştur.

Magnezyum değişkeninin Sodyum ($r=0.268, p<0.05$) ile arasında pozitif yönde zayıf düzeyde ilişki bulunmuştur.

Literatürde farklı sınıflamalar olmakla birlikte, genelde (.00,.30) zayıf düzeyde, (.31,.49) orta düzeyde, (.50,.69) güçlü düzeyde, (.70,.100) çok güçlü düzeyde ilişki olduğu şeklinde yorumlanmaktadır (Tavşancıl, 2005).

Çizelge 4.2'deki korelasyon analizine göre, Ca (Kalsiyum), Mg (Magnezyum) ve Ec (Elektriksel İletkenlik) arasında çok yüksek korelasyon katsayıları vardır. Özellikle Ca ile Ec arasında $r = 0,791$ ve Mg ile Ec arasında $r = 0,746$ gibi yüksek pozitif korelasyonlar bulunmuştur. Bu yüksek korelasyonların fiziksel ve kimyasal nedenlerini açıklamak için toprak bilimi ve iyonik etkileşimler temelinde bir yorum yapılabilir.

Çizelge 4.2. Değişkenler arasındaki korelasyon

No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1 Hacim ağırlığı	1															
2 pH	-0.016	1														
3 Ec	-.334**	0.092	1													
4 Kireç	-0.199	0.046	-0.135	1												
5 O.M.	-.265*	0.042	0.195	-0.146	1											
6 T. Kapasitesi	-.412**	-.251*	.461**	0.172	0.169	1										
7 S. Noktası	-.389**	-0.150	.619**	-0.128	0.145	.525**	1									
8 Y. S. Miktarı	-0.072	-0.127	-0.095	.309**	0.044	.579**	-.390**	1								
9 Kil	-.424**	-0.115	.613**	0.073	-0.197	.552**	.556**	0.064	1							
10 Silt	0.187	-0.013	-.360**	0.034	.247*	-.214*	-0.149	-0.089	-.470**	1						
11 Kum	.331**	0.137	-.413**	-0.106	0.036	-.453**	-.506**	-0.006	-.761**	-.215*	1					
12 KDK	-.394**	0.027	.456**	0.081	-0.074	.391**	.383**	0.055	.566**	-.230*	-.457**	1				
13 D.K. Yüzdesi	-.326**	0.159	.839**	0.056	0.122	.560**	.592**	0.039	.699**	-.262*	-.581**	.545**	1			
14 Ca	-.327**	0.151	.791**	0.081	0.026	.556**	.591**	0.035	.725**	-.300**	-.582**	.555**	.973**	1		
15 Mg	-.342**	0.093	.746**	-0.041	.245*	.409**	.611**	-0.143	.576**	-0.134	-.540**	.384**	.791**	.721**	1	
16 Na	-0.056	0.116	.260*	-0.075	.248*	0.114	0.025	0.099	-0.011	0.029	-0.009	0.105	0.184	0.130	.268*	1
17 K	0.013	0.087	.280**	0.041	0.158	0.205	0.023	0.199	0.099	-0.037	-0.082	0.164	.370**	.229*	0.010	-0.140

**P<0.001.*P<0.05

** Correlation is significant at the 0.01 level (2-tailed).

* Correlation is significant at the 0.05 level (2-tailed).

Çoklu karşılaştırma hatasını kontrol etmek için Bonferroni düzeltmesi uygulanmıştır (Armstrong, 2014). Toplam 136 korelasyon testi için anlamlılık düzeyi

$\alpha=0.05/136=0.00037$ olarak ayarlanmıştır. Pearson korelasyon katsayıları kullanılarak hesaplanmıştır (Field, 2018). Doygunluk yüzdesi ile Ca arasında çok güçlü pozitif korelasyon ($r=0.973$, $p<0.0001$), Kum ile kil arasında güçlü negatif korelasyon ($r=-0.761$, $p<0.0001$), Ec ile doymunluk yüzdesi arasında güçlü pozitif korelasyon ($r=0.839$, $p<0.0001$) saptanmıştır.

Tablo, toprak parametreleri arasındaki istatistiksel olarak anlamlı ilişkileri göstermektedir. Bonferroni düzeltmesi nedeniyle bazı orta düzey korelasyonlar istatistiksel anlamlılığını kaybetmiştir.

Korelasyon analizi, değişkenler arasındaki ilişkileri orta, güçlü ve çok güçlü olarak sınıflandırır. Ec ile hem Tarla Kapasitesi hem de Katyon Değişim Kapasitesi arasında orta düzeyde korelasyonlar gözlemlendi ve bu da tuzluluğun toprak su tutma ve besin değişimi üzerinde belirgin ancak sınırlı bir etkiye sahip olduğunu göstermektedir. Tarla Kapasitesi ile Kil, Solma Noktası ile Ec, Solma Noktası ile Kil ve Katyon Değişim Kapasitesi ile Kil arasında güçlü korelasyonlar bulundu ve bu da toprak dokusunun ve tuzluluğun nem tutma ve katyon değişim süreçlerindeki önemli rolünü vurgulamaktadır. Değiştirilebilir Katyon Yüzdesi ile hem Ec hem de Kil arasında gözlemlenen çok güçlü korelasyonlar, tuzluluğun ve daha ince toprak yapılarının katyon tutulmasını büyük ölçüde artırdığını ve toprak verimliliğindeki önemlerini doğruladığını göstermektedir. Bu sonuçlar, Ec ve kilin toprak özelliklerini etkileyen kritik faktörler olduğunu ve YSA tabanlı toprak tahminleri için değerli girdi parametreleri olduğunu vurgulamaktadır.

4.2. Fiziksel, Kimyasal ve Biyolojik Analizlerin değerlendirilmesi

Toprak numuneleri, analiz öncesinde kurutulup elendikten sonra toprağın özelliğini bozmayacak uygun kaplarda analiz yapılmaya kadar muhafaza edildi.

4.2.1. Silindir Metodu İle Hacim Ağırlığı Tayini

Toprak örneklerine ait hacim ağırlığı değerlerinin analizi, çalışma alanındaki toprakların fiziksel özellikleri hakkında önemli bilgiler sunmaktadır. Ölçülen değerlerin 1.17 g/cm^3 ile 1.76 g/cm^3 arasında değişkenlik gösterdiği ve ortalama 1.49 g/cm^3 olarak belirlendiği görülmektedir. Bu sonuçlar, toprakların genel olarak mineral toprak karakteristiği gösterdiğini ortaya koymakla birlikte, örnekler arasında belirgin bir heterojenliğin varlığına işaret etmektedir. Standart sapmanın 0.12 g/cm^3 ve varyasyon katsayısının % 8.05 olarak hesaplanması, verilerde orta düzeyde bir dağılım olduğunu göstermektedir.

Özellikle 1.17 g/cm^3 gibi düşük değerler, toprakta yüksek organik madde içeriği veya gevşek yapıyı düşündürürken, 1.76 g/cm^3 gibi yüksek değerler ise sıkışmış yapı veya kil içeriğinin fazla olduğu alanları temsil ediyor olabilir. Değerlerin büyük çoğunluğunun $1.3\text{-}1.6 \text{ g/cm}^3$ aralığında toplanması, çalışma alanındaki baskın toprak karakterini yansıtmaktadır. Bu bulgular, toprak yönetimi ve kullanım planlaması açısından önem taşımakta olup, özellikle uç değerlerin gözlendiği noktaların arazi koşulları açısından detaylı olarak incelenmesi gerekmektedir. Hacim ağırlığındaki bu değişkenliğin, toprak işleme uygulamaları, organik madde dağılımı veya toprak oluşum süreçleri gibi faktörlerden kaynaklanabileceği değerlendirilmektedir.

Çizelge 4.3. Toprak örneklerine ait hacim ağırlığı değerleri


Örnek No	Hacim Ağırlığı (g/cm^3)	Örnek No	Hacim Ağırlığı (g/cm^3)	Örnek No	Hacim Ağırlığı (g/cm^3)
1	1.63	30	1.34	59	1.61
2	1.48	31	1.34	60	1.56
3	1.28	32	1.48	61	1.41
...	...	...	...	...	...
28	1.54	57	1.48	85	1.39



Şekil 4.1. Bozulmamış numunelerin etüvde $105 \text{ }^{\circ}\text{C}$ 'de 24 saat bekletilmesi ve tartım işlemi

4.2.2. Tekstür Analizi

Toprak örneklerinin tekstür sınıflandırması, Birleşik Devletler Tarım Bakanlığı (USDA) tarafından geliştirilen tekstür üçgeni sistemi kullanılarak yapılmıştır. Bu sınıflandırmaya göre, %40'tan fazla kil içeren topraklar "Kil" sınıfına dahil edilmiştir. Kil oranı %27-40 arasında olan örnekler "Kil Tın", %20-27 aralığındaki örnekler "Tınlı Kil" olarak sınıflandırılmıştır. Kil içeriği %7-20 arasında değişen topraklar "Tın" grubuna alınırken, kil oranı %7'nin altında olan örnekler "Kumlu Tın" olarak belirlenmiştir. Tekstür sınıflandırmasında silt ve kum oranları da dikkate alınarak toprakların fiziksel özellikleri detaylı şekilde karakterize edilmiştir. Bu sınıflandırma, toprakların su tutma kapasitesi, havalanma özellikleri ve tarımsal uygunlukları hakkında önemli bilgiler sağlamaktadır (USDA, 2023).



Şekil 4.2. Tekstür analizi

Çizelge 4.4. Toprak Örneklerinin Tekstür Sınıflarına Göre Kil, Silt ve Kum İçeriklerinin Dağılımı (%)

Örnek No	Kil+Silt (%)	Kil (%)	Silt (%)	Kum (%)	USDA Tekstür Sınıfı
1	85.04	39.04	46.00	14.96	Tınlı Kil
2	85.04	47.04	38.00	14.96	Kil Tın
3	71.04	47.04	24.00	28.96	Kil Tın
...	...	...	...	...	...
85	61.04	25.04	36.00	38.96	Kumlu Tın

Çalışma kapsamında analiz edilen 85 adet toprak örneğinin tekstür bileşenleri ve USDA sınıflandırmasına göre tekstür sınıfları gösterilmektedir. Örneklerin

%42.4'ü (36 örnek) Kil Tın, %31.8'i (27 örnek) Tınlı Kil, %15.3'ü (13 örnek) Tın, %7.1'i (6 örnek) Kil ve %3.5'i (3 örnek) Kumlu Tın sınıfına girmektedir. Toplam örneklerin %74.1'inde (63 örnek) kil oranı %27'nin üzerinde olup, bu toprakların yüksek su tutma kapasitesine sahip olduğu değerlendirilmiştir. Örneklerin tekstür dağılımı incelendiğinde, çalışma alanı topraklarının genellikle killi tın ve tınlı kil tekstür sınıfında yoğunlaştığı görülmektedir.

4.2.3. Toprak Reaksiyonu (pH)

Bitkilerin gelişmeleri için mutlak gerekli olan elementlerin yararlanılabilirliği, gelişme ortamının pH'sı ya da hidrojen iyonlarının aktivitesi ile ilgilidir. Toprak, asit, nötr veya bazik olsun, çeşitli bileşiklerin çözünürlükleri, değişim yerlerine iyonların bağlanma süreçleri ve çeşitli mikroorganizmalar yine pH ile yakından ilişkilidir.

Çizelge 4.5. Toprakların pH Değerlerine Göre Sınıflandırılması ve Tarımsal Etkileri Brady ve Weil (2016); FAO (2020); USDA-NRCS (2019).

pH Aralığı	pH Sınıfı	Tarımsal Özellikler ve Etkiler	Uygun Bitkiler
4.5-5.5	Kuvvetli Asit	- Al, Mn toksisitesi riski - Ca, Mg, P, Mo eksikliği - Mikrobiyal aktivite sınırlı	- Yaban mersini - Orkide - Çay - Bazı iğne yapraklılar
5.6-6.0	Asit	- Fe, Zn, Cu alımı kolay - Fosfor fiksasyonu artar - Azot fiksasyonu sınırlı	- Patates - Çilek - Mısır - Çavdar
6.1-6.8	Hafif Asit	- Optimal besin alımı - Mikrobiyal aktivite yüksek - Çoğu bitki için ideal	- Buğday - Soya - Sebzelerin çoğu - Meyve ağaçları
6.9-7.3	Nötr	- Makro/mikro besin dengesi optimal - Organik madde ayrışması ideal	- Arpa - Pamuk - Baklagiller - Çim bitkileri
7.4-8.3	Alkalın	- Fe, Zn, Mn, Cu yarayışlılığı azalır - Fosfor çökelir - Kireç etkisi baskın	- Zeytin - Şeker pancarı - Aspir - Bazı çöl bitkileri
>8.3	Kuvvetli Alkalın	- Sodyum birikimi riski - Toprak strüktürü bozulur - Ağır metal çözünürlüğü artabilir	- Alkali toleranslı türler - Halofit bitkiler

Toprakların pH değerleri, bitki besin maddelerinin yarayışlılığı ve toprak verimliliği üzerinde doğrudan belirleyici bir faktördür. Özellikle asidik toprak koşullarında ($\text{pH} < 6.5$), alüminyum toksisitesi önemli bir sorun haline gelmektedir; zira pH değeri 5.5'in altına düştüğünde Al^{+3} iyonları çözünür hale gelerek bitki kök gelişimini olumsuz etkiler. Bu tip topraklarda kireçleme (örneğin CaCO_3 uygulaması) ile pH değeri yükseltilmeli, azot kaynağı olarak da amonyum sülfat yerine kalsiyum nitrat tercih edilmelidir. Kireçleme ihtiyacı, pH'ı her 0.1 birim artırmak için hektar başına yaklaşık 0.5–1.0 ton kireç uygulaması gerektirecek şekilde hesaplanmalıdır.

Diğer taraftan, nötr ve alkalın karakterli topraklarda ($\text{pH} > 7.5$), mikro besin maddelerinin (özellikle Fe, Zn, Mn) yarayırlılıđı azalmaktadır. Bu gibi durumlarda şelatlı mikro besin gübreleri kullanılmalı ve pH 'yı düşürmek amacıyla elementel kükürt veya jips (CaSO_4) gibi düzeltici materyaller uygulanmalıdır. pH değeri 8.5'in üzerine çıktığında, sodyum birikimi ile ilişkili sodik toprak sorunları ortaya çıkabilir; bu da toprağın yapısını bozarak geçirgenliği azaltır. Yüksek pH 'lı koşullarda özellikle şelatlı demir (Fe-EDDHA gibi) gübrelerinin kullanılması, kloroz riskinin önlenmesinde etkilidir.

Optimum toprak verimliliđi için pH 6.0–7.0 aralığı, başta fosfor olmak üzere birçok besin maddesinin en yüksek yarayırlılık gösterdiği kritik bölge olarak kabul edilmektedir. Türkiye topraklarının yaklaşık %58'i hafif alkalın (pH 7.5–8.5) özelliktedir (TÜİK, 2021). Bölgesel farklılıklar dikkate alındığında, Karadeniz Bölgesi genellikle asidik topraklara sahipken, İç Anadolu Bölgesi daha çok alkalın karakterli topraklarla temsil edilmektedir. Bu nedenle, gübreleme ve toprak ıslahı stratejileri, yerel pH değerlerine göre planlanmalı ve yönlendirilmelidir.

Çizelge 4.6. Toprak Örneklerinin pH Değerlerinin Dağılımı

Örnek No	pH	Örnek No	pH	Örnek No	pH
1	6.32	30	6.52	59	6.58
2	6.36	31	6.44	60	6.70
3	6.75	32	6.66	61	6.69
...	...	...	...	...	...
83	6.36	84	6.61	85	6.69

Çalışma kapsamında analiz edilen 85 adet toprak örneğinin pH değerleri ölçülmüştür. pH değerleri 6.30 ile 6.81 arasında değişmekte olup, ortalama pH değeri

6.52±0.13 olarak hesaplanmıştır. Örneklerin %92.9'unda (79 örnek) pH değerleri 6.3-6.7 aralığında bulunmuştur. Sadece 6 örnekte (%7.1) pH değerleri 6.7'nin üzerinde çıkmıştır. Bu sonuçlar, çalışma alanı topraklarının hafif asidik ile nötr arasında bir reaksiyona sahip olduğunu göstermektedir.

Toprakların pH değerleri bitki besin elementlerinin alınabilirliği açısından kritik öneme sahiptir. Çalışma alanı topraklarının pH aralığı, çoğu kültür bitkisinin optimal gelişimi için uygun bulunmuştur (Brady & Weil, 2016). Toprakların bu pH değerleri, organik madde içeriği ve kil mineralleri gibi faktörlerle yakından ilişkilidir.

4.2.4. Elektriksel İletkenlik ($\mu\text{S}/\text{cm}$)

Toprağın elektriksel iletkenliği (Ec), ortamda çözünmüş tuz miktarının bir göstergesidir ve toprak verimliliği üzerinde doğrudan etkisi vardır. Ec değeri arttıkça, bitkilerin su alımı zorlaşmakta ve osmotik stres nedeniyle büyüme gerilemektedir. 2 dS/m'nin altındaki topraklar genellikle tarım için güvenli kabul edilirken, 4 dS/m ve üzeri değerlerde tuz stresi önemli hale gelir. Bu tür alanlarda özellikle buğday, arpa, yonca gibi tuza dayanıklı türler tercih edilmelidir (Ayers & Westcot, 1985). Toprakların Ec değerleri tuzluluk durumunu ve bitki besin elementlerinin alınabilirliğini göstermesi açısından önemlidir. Çalışma alanı topraklarının Ec değerleri genel olarak bitki yetiştiriciliği için uygun sınırlar içerisinde bulunmuştur (Richards, 1954). Ec değerlerindeki bu değişim, toprak tekstürü, organik madde içeriği ve yöredeki drenaj koşulları gibi faktörlerle ilişkilendirilebilir.

Çizelge 4.7. Toprak Örneklerinin Elektriksel İletkenlik (Ec) Değerlerinin Dağılımı

Örnek No	Ec ($\mu\text{S}/\text{cm}$)	Örnek No	Ec ($\mu\text{S}/\text{cm}$)	Örnek No	Ec ($\mu\text{S}/\text{cm}$)
1	287	30	537	59	571
2	413	31	551	60	654
3	736	32	414	61	500
...	...	...	...	...	...
28	570	58	336	85	507

Çalışma kapsamında analiz edilen 85 adet toprak örneğinin elektriksel iletkenlik (Ec) değerleri ölçülmüştür. Ec değerleri 173.5 $\mu\text{S/cm}$ ile 1037 $\mu\text{S/cm}$ arasında değişmekte olup, ortalama Ec değeri 538.6 ± 176.3 $\mu\text{S/cm}$ olarak hesaplanmıştır. Örneklerin %85'inde (72 örnek) Ec değerleri 300-800 $\mu\text{S/cm}$ aralığında bulunmuştur. Sadece 5 örnekte (%5.9) Ec değerleri 800 $\mu\text{S/cm}$ 'nin üzerinde çıkmıştır. Bu sonuçlar, çalışma alanı topraklarının genel olarak düşük tuzluluk seviyesine sahip olduğunu göstermektedir.

4.2.5. Organik Madde (%)

Toprakların organik madde içerikleri, Jackson (1960) tarafından bildirilen yöntemle dayanılarak modifiye edilmiş Walkley-Black yöntemi ile belirlenmiştir. Toprak örneklerine ait organik madde (% O.M.) değerleri incelendiğinde, değerlerin %0.84 ile %4.76 arasında değiştiği görülmektedir. Bu veriler, organik madde miktarına göre yapılan sınıflandırmaya göre değerlendirilmiştir (Kacar ve Katkat, 2010; Sezer, 2012).

Çizelge 4.8. Organik Madde (OM) Miktarına Göre Sınıflandırma

<u>OM (%)</u>	<u>Sınıf</u>	<u>Açıklama</u>
< 1.0	Çok Düşük	Organik maddece fakir
1.0 – 2.0	Düşük	Takviye edilmesi gerekir
2.1 – 3.5	Orta	Kabul edilebilir düzeyde
3.6 – 5.0	Yüksek	İyi organik madde düzeyi
> 5.0	Çok Yüksek	Zengin organik madde içeriği



Şekil 4.3. Organik Madde Analizi

Çizelge 4.9. Toprak Örneklerinin Organik Madde (O.M.) İçeriklerinin Dağılımı

Örnek No	O.M. (%)	Örnek No	O.M. (%)	Örnek No	O.M. (%)
1	0.84	30	1.77	59	1.86
2	1.95	31	2.18	60	1.60
3	1.05	32	1.16	61	2.56
...	...	...	...	...	...
28	2.12	58	2.73	85	4.63

Toplam 85 adet toprak örneği içerisinde:

- Çok düşük ($OM < 1.0$), 1 örnek (%1.2)
- Düşük ($1.0 - 2.0$), 27 örnek (%31.8)
- Orta ($2.1 - 3.5$), 33 örnek (%38.8)
- Yüksek ($3.6 - 5.0$), 22 örnek (%25.9)
- Çok yüksek ($OM > 5.0$), 0 örnek (yok)

Elde edilen veriler, incelenen toprakların çoğunlukla orta düzeyde (%38.8) organik madde içerdiğini göstermektedir. Bu durum, tarımsal üretim açısından kabul edilebilir bir seviye olmakla birlikte, organik maddenin artırılması toprak sağlığı açısından faydalı olacaktır. Diğer yandan örneklerin yaklaşık üçte biri (%31.8) düşük seviyede organik maddeye sahiptir. Bu alanlarda organik materyal (kompost, yeşil gübre, ahır gübresi vb.) takviyesi önerilmektedir.

Yüksek organik madde sınıfına giren örneklerin oranı da dikkat çekicidir (%25.9). Bu alanlarda organik maddenin doğal yollarla biriktiği ya da düzenli organik madde uygulandığı düşünülebilir.

Çok yüksek (>5.0%) organik madde içeren örneğe rastlanmamıştır; bu da bölgenin humusça aşırı zengin olmadığını göstermektedir.

4.2.6. Kireç İçeriği (%)

Kireç içerikleri (Çağlar, 1949; Evliya, 1964)'e göre sınıflandırılmıştır. Toprakların kireç içeriklerine göre durumları;

Kireç içeriği (%)

- < 1.0 Çok az
- 1.0 – 5.0 Az
- 5.0 – 15.0 Orta
- 15.0 – 25.0 Fazla
- > 25.0 Çok fazla

Kireç içerikleri %1.87 ile %7.29 arasında değişmekte olup, ortalama 3.89 ± 1.21 olarak hesaplanmıştır. Kireç içeriğindeki bu dağılım (%1.87-7.29), çalışma alanındaki ana materyal farklılıkları ve ayrışma süreçleriyle açıklanabilir (Loeppert ve Suarez, 1996). Örneklerin %72'sinde (61 örnek) kireç içeriği %2-5 aralığında bulunmuştur. Kireç içeriği toprakların tamponlama kapasitesi ve pH

dengesi açısından önemlidir

Topraklar kireç içeriğine göre:

- %0-2: Çok az kireçli (5 örnek, %5.9)
- %2-5: Orta kireçli (61 örnek, %71.8)
- %5-10: Kireçli (19 örnek, %22.4)
- %10: Çok kireçli (Bu çalışmada yok)

şeklinde sınıflandırılabilir (Soil Survey Staff, 2014). Kireç içeriğinin bitki besin elementlerinin alınabilirliği üzerinde önemli etkileri bulunmaktadır.

Çizelge 4.10. Toprak Örneklerinin Kireç İçeriklerinin Dağılımı (%)

Örnek No	Kireç (%)	Örnek No	Kireç (%)	Örnek No	Kireç (%)
1	6.31	30	2.31	59	3.91
2	7.11	31	4.62	60	4.62
3	7.29	32	3.55	61	4.44
...	...	...	...	...	...
28	2.84	58	3.55	85	4.00

4.2.7. Toprakta Değişebilir Katyon Analizi (me100gr-1)

Toprak örneklerinde yapılan değişebilir katyon analizleri sonucunda sodyum (Na^+), potasyum (K^+), magnezyum (Mg^{+2}) ve kalsiyum (Ca^{+2}) miktarlarının geniş bir aralıkta değiştiği belirlenmiştir. Sodyum değerleri 20.96 ile 110.1 ppm arasında değişmiş olup, örneklerin büyük çoğunluğunda düşük ila orta düzeyde Na birikimi tespit edilmiştir. Ancak bazı örneklerde (özellikle 60. ve 80. örneklerde) sodyum düzeyinin 100 ppm'in üzerinde olduğu görülmüştür. Bu durum, sodyum birikimine

bağlı olarak toprakta alkali özelliklerin oluşabileceğine ve yapısal bozulmaların meydana gelebileceğine işaret etmektedir. Yüksek Na içeriği, özellikle geçirgenliği düşük killi topraklarda fiziksel özelliklerin bozulmasına neden olabilir (Brady & Weil, 2016).

Potasyum değerleri ise 37.41 ile 488.0 ppm arasında değişmiş, genel olarak yeterli düzeyde bulunmuştur. Özellikle 76. numaralı örnekte belirlenen 488 ppm'lik potasyum seviyesi dikkat çekicidir. Bu denli yüksek K konsantrasyonu, bölgesel olarak aşırı gübreleme, organik madde birikimi veya potasyumca zengin minerallerin varlığına bağlı olabilir. Yüksek potasyum düzeylerinin, magnezyum ve kalsiyum ile olan dengenin bozulmasına yol açabileceği bilinmektedir.

Magnezyum miktarları ise 88.88 ppm ile 1021.0 ppm arasında değişmiştir. Genel olarak örneklerde orta ila yüksek düzeyde Mg tespit edilmiş, 79., 80. ve 81. numaralı örneklerde ise bu elementin anormal şekilde yüksek olduğu ($Mg > 900$ ppm) gözlemlenmiştir. Bu değerler, toprakta Mg fazlalığına işaret etmekte olup, bazı durumlarda kalsiyum ve potasyumun bitki tarafından alınımı engelleyebileceği için dikkatle değerlendirilmelidir. Ancak Mg/Ca oranları genel olarak kabul edilebilir düzeydedir.

Kalsiyum değerleri ise 615.3 ppm ile 3520 ppm arasında oldukça geniş bir aralıkta değişmiş olup, ortalama değerlerin 1500–1800 ppm civarında olduğu belirlenmiştir. Bu sonuçlar, çalışılan toprakların kalsiyum yönünden zengin ve büyük olasılıkla kireçli karakterde olduğunu göstermektedir. En yüksek Ca içeriği 3 numaralı örnekte (3520 ppm) tespit edilmiştir. Kalsiyumun toprak pH'ı, yapı dengesi ve bitki gelişimi üzerinde olumlu etkileri olduğundan, bu durum olumlu bir özellik olarak değerlendirilmektedir. Bununla birlikte, kalsiyum ile magnezyum arasındaki oranın (genellikle 4:1 civarında olması ideal kabul edilir) dengede olması, toprak sağlığı açısından önemlidir (Horneck & Hanson, 1998).

Genel olarak değerlendirildiğinde, toprak örneklerinin büyük bir kısmı değişebilir katyonlar bakımından yeterli düzeyde olup, yalnızca birkaç örnekte Na^+ ve Mg^{+2} birikimine dikkat edilmesi gerekmektedir (FAO, 2021).



Şekil 4.4. Değişebilir Katyon Analizi

Çizelge 4.11. Toprak Örneklerinde Değişebilir Katyon Dağılımları (me100g-1)

Örnek No	Na (ppm)	Mg (ppm)	K (ppm)	Ca (ppm)
1	74.91	175.10	84.11	1131.00
2	28.28	309.00	138.70	1758.00
3	31.87	257.10	151.00	3520.00
...	...	...	...	...
85	98.31	348.10	59.55	1320.00

4.2.8. KDK (Katyon Değişim Kapasitesi) (me 100g-1)

Toprakların katyon değişim kapasitesi (KDK), toprak kolloidlerinin (kil mineralleri ve organik madde) pozitif yüklü katyonları tutabilme kapasitesini ifade eder ve genellikle $\text{me } 100\text{g}^{-1}$ (miliekivalan/100 gram toprak) birimiyle değerlendirilir. KDK, özellikle toprakların besin elementi tutma kapasitesi, verimlilik seviyesi ve toprak sınıfının belirlenmesi açısından kritik öneme sahiptir (Brady & Weil, 2016).

Çalışmada analiz edilen 85 toprak örneğinde KDK değerleri 35.38 ile 85.28

me100g⁻¹ arasında değişmiştir. Genel ortalama yaklaşık 61.4 me 100g⁻¹ olarak hesaplanmıştır. Bu değerler, toprakların katyonları tutma kapasitesi açısından orta-yüksek düzeyde verimli olduğunu göstermektedir. Özellikle 2 (85.28 me100g⁻¹), 13 (84.05 me100g⁻¹) ve 21 (82.33 me100g⁻¹) numaralı örneklerde ölçülen yüksek KDK değerleri, bu toprakların yüksek kil içeriğine veya organik madde zenginliğine sahip olduğunu düşündürmektedir.

Öte yandan, 26 (37.60 me100g⁻¹), 51 (35.38 me 100g⁻¹), 53 (38.05 me 100g⁻¹) ve 68 (39.32 me 100g⁻¹) numaralı örneklerde ölçülen düşük KDK değerleri, bu toprakların muhtemelen kumlu yapıdaki, organik maddece zayıf ya da düşük kil içeriğine sahip profiller olduğunu işaret etmektedir (Hazelton & Murphy, 2007).

Çizelge 4.12. Toprak Örneklerinin Katyon Değişim Kapasitelerinin (KDK) Dağılımı

Örnek No	KDK (me100g ⁻¹)	Örnek No	KDK (me100g ⁻¹)	Örnek No	KDK (me100g ⁻¹)
1	65.03	30	77.98	59	65.18
2	85.28	31	78.95	60	74.90
3	80.68	32	74.03	61	58.35
...	...	...	...	...	...
28	51.22	58	70.33	85	61.81

KDK sınıflandırması:

- <20 meq/100g: Çok düşük (kumlu)
- 20-50 meq/100g: Orta (tınlı)
- 50 meq/100g: Yüksek (killi/organik)
- (Soil Survey Staff, 2014)

Toprakta yüksek KDK, daha fazla besin tutma kapasitesi ve tarımsal üretimde istikrar anlamına gelirken, düşük KDK'ye sahip topraklar gübrelemeye daha duyarlı olup, besin kayıplarına karşı dikkatli yönetim gerektirir. Çalışmadaki genel dağılım, bölgedeki toprakların büyük ölçüde besin açısından zengin, iyi tamponlanmış ve

tarımsal üretime uygun olduğunu ortaya koymaktadır.

4.2.9. Tarla Kapasitesi

Tarla kapasitesi (TK), toprakların doygun hale geldikten sonra serbest suyun yerçekimi etkisiyle süzülmesinden sonra bünyesinde tutabildiği su miktarını ifade eder. Genellikle hacimce veya kütlece yüzde olarak belirtilen bu parametre, bitkilerin erişebileceği suyun üst sınırını oluşturur (Brady & Weil, 2016). Bu bağlamda TK, tarımsal üretimde sulama programlarının planlanması, toprak-su yönetimi, kuraklık riski değerlendirmeleri gibi konular için önemli bir göstergedir.

Bu çalışmada analiz edilen 85 toprak örneğinde tarla kapasitesi değerleri %15.19 ile %41.82 arasında değişmektedir. Genel ortalama yaklaşık %27.8 olarak hesaplanmıştır. Bu değer, çalışılan toprakların büyük bir bölümünün orta düzey su tutma kapasitesine sahip olduğunu göstermektedir.

En yüksek TK değerine sahip örnekler 22 (%41.82), 21 (%40.70) ve 15 (%37.93) numaralı örneklerdir. Bu durum, söz konusu toprakların muhtemelen yüksek oranda kil minerali veya organik madde içerdiğini göstermektedir (Rowell, 1994). Diğer yandan, 67 (%15.19), 45 (%15.83) ve 68 (%16.60) numaralı örneklerde gözlenen düşük TK değerleri, bu alanlarda kumlu veya düşük yapısal bağlılığa sahip toprakların baskın olduğunu göstermektedir. Bu tip topraklarda su hızlı şekilde süzülür ve bitkiler için yeterli süre tutulamayabilir. Tarla kapasitesi değerlerindeki bu dağılım, toprakların tekstür ve organik madde içeriklerindeki farklılıklarla açıklanabilir (Hillel, 1998). Örneklerin %68'inde (58 örnek) tarla kapasitesi değerleri %20-30 aralığında bulunmuştur.

Çizelge 4.13. Toprak Örneklerinin Tarla Kapasitesi Değerlerinin Dağılımı (%)

Örnek No	Tarla Kapasitesi (%)	Örnek No	Tarla Kapasitesi (%)	Örnek No	Tarla Kapasitesi (%)
1	32.42	30	23.91	59	23.59
2	34.19	31	22.89	60	23.45
3	33.87	32	23.25	61	24.09
...	...	...	...	...	...
28	27.71	58	16.62	85	24.25

Tarla kapasitesi sınıflandırması:

- **Düşük:** <%20 (kumlu topraklar)
- **Orta:** %20-30 (tınlı topraklar)
- **Yüksek:** >%30 (killi ve organik maddece zengin topraklar)
- (Soil Survey Staff, 2014).

Çalışma alanı topraklarının %42'si orta, %35'i yüksek tarla kapasitesine sahiptir. Dolayısıyla, tarla kapasitesi verileri alan bazlı olarak sulama verimliliği ve toprak yönetimi kararlarında dikkate alınmalı; düşük TK'ye sahip alanlarda organik madde ilavesi, malçlama veya toprak iyileştirme uygulamaları önerilebilir (FAO, 2006).

4.2.10. Solma Noktası

Toprakların su tutma kapasitesine ilişkin önemli bir parametre olan solma noktası, bitkilerin mevcut suyu almayı bıraktığı ve solmaya başladığı toprak nem düzeyini ifade eder. Çalışmada incelenen 85 adet toprak örneğinde solma noktası değerleri %3.94 ile %27.93 arasında değişim göstermiştir (Çizelge 4.14). Bu durum, toprakların fiziksel özellikleri, özellikle doku yapıları (kil, silt ve kum oranları) ile doğrudan ilişkilidir. Örneğin 58 numaralı örnekte tespit edilen %3.94'lük en düşük solma noktası, muhtemelen yüksek oranda kum içeren ve su tutma kapasitesi zayıf olan bir toprak yapısını işaret etmektedir. Buna karşılık, 81 numaralı örnekte görülen

%27.93'lük en yüksek değer, yüksek kil içeriğiyle ilişkili olabilir ve bu tür toprakların suyu daha uzun süre tutma eğiliminde olduğu bilinmektedir (Brady & Weil, 2017).

Solma noktası değerlerinin büyük bir kısmı %15 ile %25 arasında yoğunlaşmakta olup, bu aralık bitki gelişimi açısından kritik bir eşik olarak değerlendirilebilir. Bu dağılım, çalışmanın yürütüldüğü alanlarda toprakların genel olarak orta tekstür sınıfında (tınlı, killi-tınlı vb.) olduğunu düşündürmektedir. Ayrıca, bazı örneklerdeki yüksek solma noktası değerleri, tarımsal sulama uygulamaları açısından dikkate alınmalıdır. Bu tip topraklarda bitkilerin erişebileceği kullanılabilir su miktarı düşük olabileceğinden, sulama sıklığı ve zamanı özel olarak planlanmalıdır (Özbek, 1979).

Çizelge 4.14. Toprak Örneklerinin Solma Noktası Değerlerinin Dağılımı (%)

Örnek No	Solma Noktası (%)	Örnek No	Solma Noktası (%)	Örnek No	Solma Noktası (%)
1	13.68	30	20.59	59	9.46
2	17.50	31	18.87	60	9.66
3	16.33	32	17.68	61	9.50
...	...	...	...	...	...
28	15.59	58	3.94	85	17.45

Solma noktası sınıflandırması:

- **Kumlu topraklar:** <%10
- **Tınlı topraklar:** %10-20
- **Killi topraklar:** >%20
- (Soil Survey Staff, 2014).

Çalışma alanı örneklerinin %42'si tınlı, %35'i killi, %23'ü kumlu tekstür karakteri göstermektedir. Genel olarak solma noktası değerleri, hafif bünyeli topraklarda daha düşük (%8–12), ağır bünyeli ve organik maddece zengin topraklarda ise daha yüksek (%20 ve üzeri) seviyelerde seyretmektedir. Özellikle 70–85 numaralı örneklerdeki yüksek solma noktası değerleri, bu toprakların muhtemelen daha kil oranı yüksek ya da organik maddece zengin profillere sahip olduğunu düşündürmektedir. Buna karşılık 67 ve 68 numaralı örneklerdeki düşük değerler, bu toprakların kumlu ya da düşük agregat yapısına sahip olduğunu işaret etmektedir.

Literatürde de belirtildiği üzere, solma noktası değerleri toprak tipine, yapısına ve özellikle kil mineralojisine bağlı olarak değişiklik göstermektedir (Şensoy vd., 2013; Özcan ve Ersahin, 2001). Bu bağlamda, çalışma alanındaki toprakların fiziksel özelliklerinin değişkenliği, solma noktası üzerinde doğrudan etkili olmuştur. Solma noktası verileri, tarla kapasitesi ile birlikte değerlendirildiğinde, bitki yetiştiriciliğinde sulama suyu yönetimi açısından önemli bir rehber niteliği taşımaktadır.

4.2.11. Yarayışlı Su İçeriği

Yararlı su içeriği (YSİ), bitkinin kullanabileceği suyu temsil etmekte olup, tarla kapasitesi ile solma noktası arasındaki fark olarak hesaplanır. İncelenen 85 toprak örneğinde YSİ değerleri %1.06 ile %25.27 arasında değişmektedir. En yüksek yararlı su miktarı 22 numaralı örnekte (%25.27), en düşük ise 33 numaralı örnekte (%1.06) ölçülmüştür. Ortalama değerler genel olarak orta düzeyde (%10–15) seyretmiş olup, bu da bölge topraklarının su tutma kapasitesinin sınırlı olduğunu göstermektedir.

Özellikle 29 numaralı örnekte görülen çok düşük YSİ (%2.20), bu toprakların yapısal olarak suyu tutmakta yetersiz olduğunu işaret ederken; 70 ve 22 numaralı örneklerdeki yüksek değerler, bu alanların daha kilce zengin, dolayısıyla su tutma kapasitesi yüksek yapıya sahip olduğunu göstermektedir. Bu durum, sulama yönetimi planlanırken her bir toprak tipinin su tutma kapasitesinin göz önünde bulundurulmasının gerekliliğini ortaya koymaktadır.

Çizelge 4.15. Toprak Örneklerinin Yarayışlı Su İçeriği Dağılımı (%)

Örnek No	Yarayışlı Su İçeriği (%)	Örnek No	Yarayışlı Su İçeriği (%)	Örnek No	Yarayışlı Su İçeriği (%)
1	18.74	30	3.33	59	14.12
2	16.69	31	4.02	60	13.79
3	17.55	32	5.57	61	14.59
...	...	...	...	...	...
28	12.11	58	12.68	85	6.79

4.3. Solhan Ovası Arazilerin Tanımlayıcı İstatistikleri

Çalışma alanı topraklarının Hacim Ağırlığı içerikleri 1.17 g/cm^3 ile 1.76 g/cm^3 arasında değişmektedir, ortalama Hacim ağırlığı içeriği 1.49 g/cm^3 'tür.

Araştırılan bir diğer özellik ise pH değeridir. Bitki gelişimi açısından pH değerinin en uygun olduğu aralığı 6.5 ile 7.5 arasında olduğu belirlenmiştir. Çalışma alanındaki toprakların pH değerlerinin 6.30 ile 6.81 arasında değiştiği belirlenmiştir.

Çalışma alanındaki toprakların Ec değerlerinin $0.17 \text{ (dS m}^{-1}\text{)}$ ile $1.03 \text{ (dS m}^{-1}\text{)}$ arasında, ortalamanın ise $0.54 \text{ (dS m}^{-1}\text{)}$ olduğu belirlenmiştir.

Çalışma alanı topraklarının Kireç içeriklerinin %1.78 ile %7.29 arasında değiştiği, ortalamanın %3.92 olduğu tespit edilmiştir.

Çalışma alanı topraklarının Organik Madde içeriği %0.84 ile %4.76 arasında değişmiş, ortalama %2.5 olduğu belirlenmiştir.

Toprak kalitesinin önemli bir göstergesi olan kullanılabilir su içeriği, tarla kapasitesi ile solma noktası arasındaki fark olarak hesaplanmaktadır (Malgwi ve Abu, 2011; Sağlam, 2013).

Çalışma alanı topraklarının Yarayışlı su miktarı yüzdesi içeriklerinin %1.06 ile %25.27 arasında değiştiği, ortalamanın %10.15 olduğu tespit edilmiştir.

Çalışma alanı topraklarının Katyon Değişim Kapasitesinin $35.38 \text{ (meq } 100\text{g}^{-1}\text{)}$ ile $85.28 \text{ (meq } 100\text{g}^{-1}\text{)}$ arasında değiştiği, ortalamanın $60.53 \text{ (meq } 100\text{g}^{-1}\text{)}$ olduğu

tespit edilmiştir.

Çalışma alanı topraklarının Değişebilir Katyon Yüzdesinin %16.06 ile %46.98 arasında değiştiği, ortalamanın %28.31 olduğu tespit edilmiştir.

Çalışma alanı topraklarında Değişebilir Katyonlardan Ca, Mg, Na ortalamalarını yüksek, K ortalamasının ise çok yüksek olduğu tespit edilmiştir.

Çalışma alanındaki toprakların ağırlıklı olarak killi-tınlı olduğu belirlenmiştir.

Çizelge 4.1. Tanımlayıcı İstatistikler

İSTATİSTİKLER	Ortalama	S.H.	S.S.	V.K.	Basıklık	Çarpıklık	Arahık	Min	Max
Hacim ağırlığı	1.49	0.01	0.13	0.02	-0.58	-0.03	0.59	1.17	1.76
pH	6.52	0.01	0.13	0.02	-0.86	0.29	0.51	6.30	6.81
Ec	0.54	0.01	0.15	24.79	0.41	0.42	0.86	0.17	1.03
Kireç	3.92	0.12	1.12	1.26	1.14	0.73	5.51	1.78	7.29
O.M.	2.50	0.11	0.97	0.94	-0.39	0.77	3.92	0.84	4.76
T.K.	26.91	0.62	5.74	32.93	-0.26	0.19	26.63	15.19	41.82
S.N.	16.76	0.55	5.08	25.84	-0.20	-0.01	23.99	3.94	27.93
Y.S.Miktarı	10.15	0.58	5.31	28.15	-0.53	0.39	24.21	1.06	25.27
Kil	38.86	0.85	7.88	62.03	-0.73	-0.19	34.00	21.04	55.04
Silt	32.02	0.47	4.29	18.43	-0.30	0.27	18.00	24.00	42.00
Kum	29.11	0.68	6.29	39.56	-0.42	0.37	28.00	14.96	42.96
KDK	60.53	1.31	12.11	146.62	-0.66	-0.14	49.90	35.38	85.28
D.K. Yüzdesi	28.31	0.65	6.01	36.07	0.73	0.41	30.92	16.06	46.98
Ca	19.73	0.48	4.46	19.91	1.52	0.68	24.55	11.27	35.83
Mg	3.94	0.13	1.23	1.52	0.25	0.02	5.92	1.11	7.03
Na	1.21	0.05	0.45	0.20	2.68	1.44	2.23	0.52	2.75
K	3.43	0.16	1.47	2.16	3.86	1.71	7.81	0.94	8.74

Min: Minimum değer, Max: Maksimum değer, AO: Aritmetik ortalama, S.S: Standart sapma, VK: Varyasyon katsayısı (%),

Ec: Elektriksel iletkenlik (dSm⁻¹), KDK: Katyon değişim kapasitesi (meq 100g⁻¹), DK: Değişebilir Katyon (%), OM: Organik madde (%)

4.4. Yapay Sinir Ağları ile Toprak Kalite Parametre Tahmini

Yapay Zeka teknikleri ve Makine Öğrenmesi alanındaki gelişmeler, toprak özelliklerinin doğru tahminine olanak tanıyan yeni yöntemler sağlamıştır. Özellikle, Yapay Sinir Ağları (YSA) kullanan toprak haritalama çalışmaları bu alanda önemli bir yenilik yaratmıştır (Minasny ve Hartemink, 2011). Bu yöntemler, geleneksel toprak haritalama yaklaşımlarının sınırlamalarını aşmak için geliştirilmiştir. Uydu görüntüleri ve saha verilerinden elde edilen toprak ve çevresel değişkenler arasındaki ilişkilere dayalı olarak toprak özelliklerinin tahmin edilmesini sağlarlar (McBratney ve diğerleri, 2003). Çeşitli yeni çalışmalar, toprak pH'ı (Pahlavan-Rad ve Akbarimoghaddam, 2018), organik madde içeriği (Byrne ve Yang, 2016), elektriksel iletkenlik (Ranjbar ve Jalali, 2016), fosfor seviyeleri (Wilson ve diğerleri, 2016) ve toprak parçacık boyutu dağılımı (Pahlavan-Rad ve Akbarimoghaddam, 2018) gibi parametrelerin tahminini ve haritalanmasını sağlamıştır. Veri madenciliği alanında, yapay sinir ağları büyük veri kümelerini etkili bir şekilde işleme kapasiteleri ve

genelleme yetenekleri ile bilinirler (Zhu, 2000; Behrens vd., 2005; Boruvka ve Penizek, 2007).

Sinir ağı tabanlı sistemler, özellikle giriş katmanı, arka plan katmanı ve çıktı katmanlarını kullanarak ileri beslemeli ve geri yayımlı ağlarla sınıflandırma ve tahmin amaçları için birçok alanda uygulanır.

Bu çalışmada, saha ve laboratuvar koşullarında belirlenmesi zor, maliyetli ve ölçülmesi uzun zaman alan toprak parametrelerini tahmin etmede YSA modellerinin etkinliği araştırılmıştır. Çalışmada, YSA yöntemlerinin toprakların fiziksel, kimyasal ve biyolojik özelliklerini tahmin etmedeki başarısı değerlendirilmiştir. Önceki çalışmalar, YSA modellerinin diğer yöntemlerden daha güvenilir tahminler sağladığını ve mühendislik çabalarını, zamanı ve maliyetleri azaltarak toprak özelliklerini kabul edilebilir doğrulukla tahmin edebileceğini göstermiştir.

Hiperparametre optimizasyonu, model karmaşıklığını dengeleyebilir ve böylece aşırı uyum ve yetersiz uyum arasında bir denge sağlayabilir. Modelin esnekliğinden kaynaklanan aşırı uyum sorunu, hiperparametrelerin getirdiği kısıtlamalarla çözülebilir (Yang ve Shami, 2020). Modelin giriş verileri, analizi kolay, düşük maliyetli ve hızlı olan Elektriksel İletkenlik (Ec) ve Kil parametrelerinden oluşmuştur ve tek katmanlı ve çift katmanlı yapılar kullanılmıştır.

Her gizli katmanda 0-30 nöron kullanılarak farklı Yapay Sinir Ağı modelleri oluşturulmuştur. Veriler %70 eğitim, %15 test ve %15 doğrulama veri kümelerine ayrıldı. Üç farklı algoritma incelendi: Levenberg-Marquardt, Ölçekli Eşlenik Gradyan ve Bayes Düzenlemesi. Bu algoritmalar, iki gizli katman modelinin Solma Noktası, Değiştirilebilir Katyon Yüzdesi, Tarla Kapasitesi ve Katyon Değişim Kapasitesi gibi parametrelerini tahmin etmek için kullanıldı.

4.4.1. Yapay Sinir Ağlarının Kullanımı

Yapay Sinir Ağı girdi verisi olarak analizi düşük maliyetli, kısa zaman alan ve ileri derecede uzmanlık gerektirmeyen Ec ve kil verisi olan, tek ve çift gizli katmanlı, farklı iterasyon sayılarında oluşturulan sinir ağı modelleri ile analizi; yüksek maliyetli, uzun zaman alan ve ileri derecede uzmanlık gerektiren parametrelerin tahmini için sinir ağı modelleri oluşturulmuştur.

4.4.2. Yapay Sinir Ağları ile Değiştirilebilir Katyon Yüzdesi tahmini

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Levenberg-Marquardt algoritması için Çizelge 4.16 incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-7-5-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 75 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.85 - 1.705 - 2.225 ve 0.86 - 1.752 - 2.278 olarak belirlenmiştir.

Çizelge 4.16. Değişebilir Katyon Yüzdesi tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE
Ec, Kil	(2-7-5-1)	75	0.85	1.705	2.255	0.36	0.093	0.135	0.86	1.752	2.278
	(2-3-5-1)	25	0.86	1.733	2.224	0.31	0.097	0.124	0.86	1.803	2.282
	(2-3-10-1)	75	0.84	1.760	2.356	0.72	0.098	0.117	0.86	1.731	2.283
	(2-5-3-1)	75	0.85	1.692	2.255	-3.11	0.204	0.322	0.86	1.729	2.284
	(2-8-7-1)	100	0.86	1.717	2.185	-2.17	0.107	0.209	0.86	1.799	2.287
	(2-3-9-1)	50	0.85	1.749	2.263	0.72	0.059	0.092	0.86	1.824	2.292
	(2-7-3-1)	100	0.85	1.703	2.265	0.52	0.115	0.149	0.86	1.758	2.298
	(2-2-6-1)	100	0.86	1.602	2.193	0.73	0.071	0.097	0.86	1.693	2.303
	(2-3-10-1)	75	0.85	1.681	2.292	0.71	0.070	0.108	0.86	1.671	2.310
	(2-4-5-1)	25	0.85	1.679	2.285	0.79	0.075	0.090	0.86	1.722	2.314

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Scaled Conjugate Gradient algoritması için Çizelge 4.17. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-12-11-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 50 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.70 - 0.081 - 0.103 ve 0.92 - 0.048 - 0.061 olarak belirlenmiştir.

Çizelge 4.17. Değişebilir Katyon Yüzdesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE
Ec. Kil	(2-12-11-1)	50	0.70	0.081	0.103	0.75	0.077	0.089	0.92	0.048	0.061
	(2-11-27-1)	50	0.64	0.090	0.120	0.43	0.082	0.087	0.91	0.046	0.051
	(2-16-1)	50	0.66	0.082	0.107	0.80	0.060	0.085	0.91	0.047	0.063
	(2-27-22-1)	100	0.73	0.081	0.104	0.61	0.086	0.111	0.90	0.042	0.052
	(2-26-13-1)	75	0.62	0.076	0.109	0.76	0.078	0.102	0.90	0.047	0.074
	(2-30-29-1)	75	0.76	0.071	0.095	0.49	0.087	0.107	0.90	0.055	0.072
	(2-15-22-1)	75	-0.06	0.125	0.173	0.42	0.156	0.188	0.89	0.056	0.069
	(2-25-20-1)	50	0.63	0.087	0.109	0.54	0.101	0.135	0.89	0.064	0.077
	(2-25-9-1)	100	0.79	0.062	0.084	0.28	0.149	0.179	0.89	0.052	0.068
	(2-21-13-1)	25	0.69	0.087	0.110	0.32	0.098	0.122	0.88	0.049	0.066

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Bayesian Düzenlemesi algoritması için Çizelge 4.18. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-28-25-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 100 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.75 - 0.068 - 0.092 ve 0.94 - 0.039 - 0.057 olarak belirlenmiştir.

Çizelge 4.18. Değişebilir Katyon Yüzdesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE
Ec. Kil	(2-28-25-1)	100	0.75	0.068	0.092	0.94	0.039	0.057
	(2-13-20-1)	100	0.74	0.077	0.101	0.93	0.033	0.041
	(2-18-7-1)	25	0.60	0.093	0.123	0.93	0.040	0.048
	(2-27-7-1)	100	0.80	0.063	0.087	0.91	0.041	0.053
	(2-22-26-1)	50	0.71	0.077	0.102	0.91	0.048	0.061
	(2-22-26-1)	75	0.73	0.074	0.100	0.91	0.046	0.059
	(2-5-16-1)	75	0.79	0.065	0.090	0.91	0.045	0.053
	(2-16-15-1)	50	0.74	0.075	0.100	0.90	0.047	0.057
	(2-27-14-1)	50	0.76	0.070	0.094	0.90	0.037	0.060
	(2-2-23-1)	25	0.76	0.071	0.094	0.89	0.050	0.067

4.4.3. Yapay Sinir Ağları ile Katyon Değişim Kapasitesi Tahmin

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Levenberg-Marquardt algoritması için Çizelge 4.19 incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-26-2-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 50 iterasyonda ulaşılmıştır. Buna

göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.73 - 0.439 - 0.533 ve 0.62 - 0.414 - 0.630 olarak belirlenmiştir.

Çizelge 4.19. Çizelge 20. Katyon Değişim Kapasitesi tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE
Ec, Kil	(2-26-2-1)	50	0.73	0.439	0.533	0.27	0.174	0.215	0.62	0.414	0.630
	(2-1-3-1)	100	0.68	0.500	0.577	0.15	0.140	0.180	0.39	0.630	0.799
	(2-2-30-1)	100	0.63	0.539	0.623	0.13	0.188	0.229	0.41	0.639	0.787
	(2-26-1-1)	25	0.62	0.494	0.629	0.28	0.159	0.197	0.42	0.581	0.778
	(2-1-10-1)	100	0.61	0.553	0.640	0.10	0.174	0.216	0.40	0.604	0.792
	(2-1-11-1)	25	0.60	0.558	0.649	-0.26	0.236	0.250	0.38	0.615	0.806
	(2-4-25-1)	25	0.89	0.521	0.653	0.29	0.193	0.230	0.83	0.289	0.423
	(2-1-16-1)	25	0.57	0.577	0.670	0.27	0.189	0.249	0.39	0.604	0.796
	(2-2-24-1)	100	0.57	0.589	0.673	0.13	0.193	0.243	0.41	0.589	0.785
	(2-2-2-1)	50	0.55	0.550	0.684	0.12	0.177	0.197	0.46	0.579	0.749

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Scaled Conjugate Gradient algoritması için Çizelge 4.20. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-28-16-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 75 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.50 - 0.134 - 0.170 ve 0.79 - 0.096 - 0.115 olarak belirlenmiştir.

Çizelge 4.20. Çizelge 21. Katyon Değişim Kapasitesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE
Ec, Kil	(2-28-16-1)	75	0.50	0.134	0.170	0.10	0.189	0.226	0.79	0.096	0.115
	(2-11-8-1)	100	0.10	0.174	0.220	0.44	0.139	0.168	0.77	0.109	0.132
	(2-26-15-1)	75	0.36	0.159	0.194	0.09	0.177	0.198	0.72	0.104	0.136
	(2-27-9-1)	25	0.27	0.176	0.211	0.36	0.141	0.183	0.70	0.094	0.113
	(2-17-4-1)	25	0.33	0.171	0.203	0.62	0.093	0.119	0.69	0.114	0.138
	(2-3-26-1)	50	0.28	0.168	0.203	0.34	0.173	0.209	0.69	0.102	0.130
	(2-29-10-1)	75	0.30	0.143	0.177	0.28	0.228	0.258	0.69	0.116	0.152
	(2-3-14-1)	50	0.37	0.156	0.190	0.19	0.144	0.180	0.68	0.131	0.156
	(2-11-19-1)	75	0.37	0.159	0.201	0.46	0.131	0.158	0.68	0.094	0.113
	(2-11-27-1)	100	0.33	0.164	0.198	0.09	0.219	0.245	0.68	0.101	0.117

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Bayesian Düzenlemesi algoritması için

Çizelge 4.21. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-2-24-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R^2 ve en düşük MAE ve RMSE değerlerine 25 iterasyonda ulaşılmıştır. Buna göre R^2 , MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.45 - 0.145 - 0.183 ve 0.74 - 0.099 - 0.110 olarak belirlenmiştir.

Çizelge 4.21. Katyon Değişim Kapasitesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
			R^2	MAE	RMSE	R^2	MAE	RMSE
Ec. Kil	(2-2-24-1)	25	0.45	0.145	0.183	0.74	0.099	0.110
	(2-4-24-1)	75	0.30	0.177	0.211	0.73	0.073	0.091
	(2-6-5-1)	75	0.29	0.175	0.209	0.72	0.078	0.108
	(2-19-13-1)	100	0.26	0.172	0.207	0.70	0.104	0.130
	(2-5-30-1)	100	0.28	0.171	0.208	0.67	0.109	0.128
	(2-30-1)	25	0.44	0.144	0.177	0.66	0.129	0.155
	(2-26-7-1)	25	0.28	0.169	0.206	0.66	0.113	0.138
	(2-29-1)	100	0.44	0.146	0.180	0.66	0.125	0.140
	(2-1-9-1)	50	0.40	0.156	0.190	0.65	0.102	0.122
	(2-20-1)	50	0.43	0.148	0.183	0.65	0.110	0.137

4.4.4. Yapay Sinir Ağları ile Tarla Kapasitesi Tahmini

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Levenberg-Marquardt algoritması için Çizelge 4.22. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-6-6-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R^2 ve en düşük MAE ve RMSE değerlerine 75 iterasyonda ulaşılmıştır. Buna göre R^2 , MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.97 - 0.560 - 1.012 ve 0.96 - 0.610 - 1.094 olarak belirlenmiştir.

Çizelge 4.22. Tarla Kapasitesi tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R^2	MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE
Ec, Kil	(2-6-6-1)	75	0.97	0.560	1.012	0.17	0.127	0.172	0.96	0.610	1.094
	(2-4-6-1)	100	0.95	0.784	1.331	-0.90	0.171	0.189	0.95	0.828	1.311
	(2-6-6-1)	75	0.95	0.654	1.336	0.40	0.147	0.169	0.94	0.695	1.362
	(2-6-4-1)	50	0.92	1.046	1.578	-1.55	0.219	0.250	0.94	0.991	1.413
	(2-6-5-1)	50	0.94	0.881	1.392	-1.61	0.211	0.223	0.93	0.924	1.475
	(2-5-6-1)	75	0.92	0.991	1.578	0.04	0.170	0.201	0.92	1.017	1.580
	(2-6-5-1)	75	0.91	1.152	1.710	-0.50	0.160	0.173	0.90	1.232	1.780
	(2-5-4-1)	100	0.90	1.245	1.832	0.09	0.153	0.181	0.90	1.253	1.821
	(2-5-3-1)	75	0.90	1.208	1.813	-0.53	0.171	0.196	0.89	1.243	1.835
	(2-5-4-1)	50	0.89	1.283	1.922	-0.23	0.209	0.245	0.88	1.314	1.974

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Scaled Conjugate Gradient algoritması için Çizelge 4.23. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-24-16-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R^2 ve en düşük MAE ve RMSE değerlerine 25 iterasyonda ulaşılmıştır. Buna göre R^2 , MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.31 - 0.135- 0.175 ve 0.73 - 0.105 - 0.125 olarak belirlenmiştir.

Çizelge 4.23. Tarla Kapasitesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R^2	MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE
Ec. Kil	(2-24-16-1)	25	0.31	0.135	0.175	0.28	0.146	0.166	0.73	0.105	0.125
	(2-25-27-1)	50	0.33	0.124	0.156	0.67	0.145	0.156	0.72	0.092	0.117
	(2-10-24-1)	75	0.40	0.140	0.168	0.27	0.131	0.162	0.71	0.085	0.116
	(2-26-20-1)	100	0.08	0.174	0.202	0.15	0.149	0.172	0.71	0.103	0.131
	(2-9-24-1)	100	0.31	0.156	0.182	0.37	0.125	0.148	0.71	0.102	0.116
	(2-24-24-1)	25	0.56	0.109	0.136	0.10	0.222	0.253	0.70	0.068	0.099
	(2-10-28-1)	100	0.25	0.165	0.188	0.08	0.154	0.173	0.70	0.099	0.125
	(2-9-19-1)	25	0.38	0.132	0.154	0.21	0.161	0.201	0.70	0.123	0.133
	(2-20-27-1)	25	0.31	0.144	0.173	0.51	0.124	0.144	0.68	0.111	0.137
	(2-13-15-1)	50	0.36	0.141	0.171	-0.07	0.155	0.174	0.68	0.116	0.127

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Bayesian Düzenlemesi algoritması için Çizelge 4.24. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-10-6-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R^2 ve en düşük MAE ve RMSE değerlerine 75 iterasyonda ulaşılmıştır. Buna göre R^2 , MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.43 - 0.135 - 0.159 ve 0.76 - 0.101 - 0.114 olarak belirlenmiştir.

Çizelge 4.24. Tarla Kapasitesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE
Ec, Kil	(2-10-6-1)	75	0.43	0.135	0.159	0.76	0.101	0.114
	(2-4-25-1)	75	0.44	0.134	0.158	0.71	0.093	0.107
	(2-25-2-1)	50	0.45	0.125	0.150	0.71	0.118	0.144
	(2-2-17-1)	100	0.46	0.131	0.154	0.69	0.104	0.128
	(2-7-25-1)	100	0.47	0.131	0.155	0.68	0.100	0.126
	(2-26-2-1)	75	0.42	0.139	0.160	0.66	0.120	0.135
	(2-3-23-1)	50	0.49	0.136	0.157	0.66	0.083	0.105
	(2-4-2-1)	25	0.46	0.132	0.155	0.65	0.123	0.135
	(2-3-9-1)	100	0.37	0.142	0.162	0.65	0.129	0.156
	(2-9-10-1)	75	0.47	0.132	0.156	0.65	0.107	0.127

4.4.5. Yapay Sinir Ağları ile Solma Noktası Tahmini

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Levenberg-Marquardt algoritması için Çizelge 4.25 incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-19-24-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 50 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.99 - 0.003 - 0.004 ve 0.99 - 0.003 - 0.004 olarak belirlenmiştir.

Çizelge 4.25. Solma Noktası tahmini için LM eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri set

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE
Ec, Kil	(2-19-24-1)	50	0.99	0.003	0.004	0.99	0.003	0.004	0.99	0.003	0.004
	(2-9-30-1)	50	0.99	0.001	0.001	0.99	0.001	0.001	0.99	0.001	0.001
	(2-23-12-1)	75	0.99	0.004	0.005	0.99	0.004	0.005	0.99	0.004	0.004
	(2-1-3-1)	50	0.99	0.003	0.004	0.99	0.003	0.005	0.99	0.003	0.004
	(2-19-26-1)	25	0.99	0.002	0.003	0.99	0.002	0.003	0.99	0.002	0.002
	(2-7-3-1)	75	0.99	0.002	0.002	0.99	0.002	0.003	0.99	0.002	0.002
	(2-23-24-1)	25	0.99	0.002	0.003	0.99	0.003	0.004	0.99	0.002	0.003
	(2-24-5-1)	75	0.99	0.003	0.004	0.99	0.003	0.004	0.99	0.002	0.003
	(2-22-8-1)	100	0.99	0.003	0.004	0.99	0.003	0.005	0.99	0.003	0.004
	(2-7-12-1)	75	0.99	0.002	0.003	0.99	0.002	0.003	0.99	0.002	0.003

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Scaled Conjugate Gradient algoritması için Çizelge 4.26. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-22-11-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 50 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında

sırasıyla 0.28 - 0.144 - 0.184 ve 0.80 - 0.081 - 0.104 olarak belirlenmiştir.

Çizelge 4.26. Solma Noktası Kapasitesi tahmini için SCG eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim, doğrulama ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Doğrulama			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE
Ec. Kil	(2-22-11-1)	50	0.28	0.144	0.184	0.47	0.075	0.093	0.80	0.081	0.104
	(2-9-10-1)	50	0.37	0.134	0.171	-0.57	0.109	0.134	0.79	0.078	0.099
	(2-2-29-1)	100	0.26	0.141	0.187	0.35	0.127	0.167	0.79	0.070	0.084
	(2-15-12-1)	25	0.30	0.129	0.170	0.62	0.117	0.149	0.78	0.075	0.097
	(2-4-22-1)	50	0.30	0.132	0.176	0.49	0.131	0.154	0.77	0.086	0.099
	(2-6-1)	100	0.28	0.140	0.177	0.26	0.133	0.173	0.73	0.077	0.116
	(2-10-13-1)	75	0.31	0.139	0.178	0.43	0.126	0.157	0.73	0.069	0.095
	(2-5-1-1)	75	0.35	0.129	0.172	0.18	0.163	0.197	0.73	0.080	0.100
	(2-20-14-1)	100	0.49	0.133	0.166	-0.96	0.175	0.211	0.72	0.065	0.075
	(2-16-13-1)	25	0.34	0.139	0.165	0.36	0.190	0.217	0.72	0.068	0.089

Yapay Sinir Ağı girdi verisinin Ec ve kil parametrelerinden oluştuğu, tek ve çift gizli katmanlı, her iki katman 0-30 nöron sayısını içeren farklı sinir ağı modelleri ile oluşturulmuştur. Bu çalışmadan elde edilen verilerin %70'i eğitim, %15'i test ve %15'i doğrulama veri seti olarak ayrılmıştır. Bayesian Düzenlemesi algoritması için Çizelge 4.27. incelendiğinde; Ec ve kil parametrelerinin girdi olarak kullanıldığı iki gizli katmanlı model (2-25-10-1) en iyi sonuç veren model olarak tespit edilmiştir. En yüksek R² ve en düşük MAE ve RMSE değerlerine 100 iterasyonda ulaşılmıştır. Buna göre R², MAE ve RMSE değerleri eğitim ve test aşamalarında sırasıyla 0.37 - 0.133 - 0.169 ve 0.86 - 0.058 - 0.069 olarak belirlenmiştir.

Çizelge 4.27. Solma Noktası Kapasitesi tahmini için BR eğitim algoritması kullanılarak farklı ağ yapıları ve iterasyonlarda belirlenen eğitim ve test veri setleri

Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
			R ²	MAE	RMSE	R ²	MAE	RMSE
Ec. Kil	(2-25-10-1)	100	0.37	0.133	0.169	0.86	0.058	0.069
	(2-22-26-1)	100	0.38	0.132	0.168	0.86	0.056	0.067
	(2-2-5-1)	100	0.36	0.132	0.168	0.85	0.059	0.073
	(2-28-18-1)	100	0.38	0.134	0.168	0.82	0.053	0.078
	(2-20-1)	50	0.38	0.128	0.168	0.81	0.068	0.084
	(2-6-28-1)	75	0.39	0.131	0.168	0.81	0.069	0.079
	(2-22-4-1)	50	0.40	0.132	0.168	0.80	0.060	0.072
	(2-24-9-1)	75	0.36	0.131	0.167	0.80	0.066	0.080
	(2-20-10-1)	100	0.40	0.133	0.168	0.79	0.061	0.077
	(2-26-10-1)	50	0.40	0.134	0.169	0.79	0.052	0.067

5. TARTIŞMA

Elektriksel İletkenlik (Ec) ve İyonik Çözünürlük

Elektriksel iletkenlik (Ec) topraktaki çözünmüş iyonların (katyonlar ve anyonlar) konsantrasyonunu ölçer. Ca^{+2} ve Mg^{+2} toprak çözeltisinde yüksek çözünürlüğe sahip iyonlardır ve bu nedenle Ec değerini önemli ölçüde artırır. Bu iyonların topraktaki konsantrasyonu arttıkça Ec değeri de doğru orantılı olarak artar. Bu durum özellikle tuzlu ve sodik topraklarda belirgindir (Shahid vd., 2018; Rhoades vd., 1999b).

Katyon Değişim Kapasitesi (KDK) ile İlişki

Ca ve Mg, toprak kolloidlerindeki (kil ve organik madde) katyon değişim bölgelerine kolayca bağlanan iyonlardır. Bu iyonların toprakta yüksek konsantrasyonlarda bulunması toprağın katyon değişim kapasitesini (KDK) artırır. KDK 'nın artması toprağın iyon tutma kapasitesini artırır, bu da Ec değerini doğrudan etkiler (Brady & Weil, 2016). Son yıllarda yapılan çalışmalar, özellikle kil minerallerinin yapısı ve organik madde içeriğinin KDK üzerinde önemli bir etkiye sahip olduğunu vurgulamaktadır (Sposito, 2016).

Toprak Tekstürü ve Kil İçeriği

Ca ve Mg ile kil içeriği arasında yüksek korelasyonlar vardır (Ca ve kil: $r = 0.725$; Mg ve kil: $r = 0.576$). Kil mineralleri yüksek KDK değerine sahip oldukları için Ca^{2+} ve Mg^{2+} iyonlarını tutma eğilimindedir. Bu da kil içeriği yüksek olan topraklarda Ec değerinin yüksek olmasına neden olur (Sparks, 2003). Son çalışmalar, kil minerallerinin, özellikle montmorillonit ve illitin, Ca ve Mg iyonlarını daha etkili bir şekilde tuttuğunu göstermektedir (Zhang vd., 2020).

Toprak Çözeltisinde İyonik Etkileşimler

Ca^{2+} ve Mg^{2+} toprak çözeltisindeki anyonlarla (örn. klorür, sülfat) birleşerek çözünür tuzlar oluşturur. Bu tuzlar toprak çözeltisindeki iyonik aktiviteyi artırır ve Ec değerini yükseltir. Özellikle kurak ve yarı kurak bölgelerde bu tuz birikimi daha belirgindir (Richards, 1954). Son çalışmalar, iklim değişikliği ve sulama uygulamalarının toprakta tuz birikimini artırdığını ve bunun da Ec değerlerini daha da yükselttiğini göstermektedir (Machado & Serralheiro, 2017).

Toprak pH'ı ve İyonik Denge

Tablo 2'de pH ile Ca ve Mg arasında anlamlı bir korelasyon yoktur. Ancak, toprak pH'ı iyonların çözünürlüğünü dolaylı olarak etkileyebilir. Örneğin, nötr veya hafif alkali pH değerleri Ca^{2+} ve Mg^{2+} iyonlarının çözünürlüğünü artırabilir ve Ec değerini yükseltebilir (Brady & Weil, 2016). Son çalışmalar toprak pH'sının mikrobiyal aktivite ve organik madde ayrışması üzerindeki etkilerinin Ec değerlerini de dolaylı olarak etkilediğini göstermektedir (Rengel, 2015).

Bu çalışmada, Ca, Mg ve Ec arasındaki yüksek korelasyonlar, bu iyonların toprak çözeltisindeki yüksek çözünürlükleri, kil mineralleri ile güçlü etkileşimleri ve kation değişim kapasitesi üzerindeki etkileri ile açıklanabilir. Bu bulgular toprak verimliliği ve yönetimi için önemli ipuçları sağlamaktadır. Özellikle Ca ve Mg gibi besin maddelerinin topraktaki dinamiklerinin anlaşılması, tarımsal uygulamalarda daha etkili stratejiler geliştirilmesine yardımcı olabilir.

Toprak kalitesinin değerlendirilmesi, sürdürülebilir tarım ekosistemlerinin yönetiminde kritik bir rol oynamaktadır. Bu çalışmada elde edilen bulgular, özellikle elektriksel iletkenlik (Ec), kation değişim kapasitesi (KDK) ve kil içeriği arasındaki güçlü korelasyonlar bağlamında değerlendirildiğinde, literatürdeki benzer çalışmalarla hem uyum hem de bazı önemli farklılıklar göstermektedir.

Shahid ve ark. (2018) ile Rhoades ve ark. (1999b)'nin tuzlu topraklarda Ec-Ca/Mg ilişkisine dair bulguları, bu çalışmada gözlenen yüksek korelasyonlarla (Ca-Ec: $r=0.791$; Mg-Ec: $r=0.746$) örtüşmektedir.

Literatürdeki önemli bir tartışma noktası, toprak pH'ının Ec üzerindeki dolaylı etkileridir. Rengel (2015) tarafından vurgulanan mikrobiyal aktivite-pH ilişkisi, bu çalışmada pH ile Ca/Mg arasında anlamlı korelasyon bulunmamasına rağmen, Ec değerlerini etkileyen önemli bir faktör olarak karşımıza çıkmaktadır. Bu bulgu, Brady ve Weil (2016)'in nötr-alkali pH'larda iyon çözünürlüğüne ilişkin savlarıyla kısmen çelişmekte olup, bu farklılık çalışma alanındaki spesifik toprak mikrobiyotaya kompozisyonuyla açıklanabilir.

Toprak kalitesi değerlendirme yaklaşımları bağlamında, Andrews ve ark. (2004) ile Govaerts ve ark. (2006)'nın çalışmalarındaki fonksiyonel kapasite vurgusu, bu araştırmada ölçülen fizikokimyasal parametrelerle desteklenmektedir. Ancak,

Askari ve Holden (2015)'in altını çizdiği yönetsel etkilerin izlenmesi boyutu, bu çalışmada uzun dönemli veri içermemesi nedeniyle tam olarak değerlendirilememiştir.

Bu çalışma, özellikle kil içeriği-Ca/Mg-Ec üçlü ilişkisindeki korelasyon katsayılarının (Ca-kil: $r=0.725$; Mg-kil: $r=0.576$), Sparks (2003)'in önceki bulgularından daha yüksek olduğunu ortaya koymuştur.

Machado ve Serralheiro (2017)'nin iklim değişikliği etkilerine dair öngörülleri, çalışma alanındaki Ec değerlerinin dağılımıyla desteklenir niteliktedir.

Richards (1954)'ın klasik tuz birikimi çalışmalarıyla uyumlu olarak, kurak koşullarda Ca/Mg tuzlarının Ec'ye katkısı net şekilde gösterilmiştir.

Bu çalışmanın bulguları, toprak kalite indekslerinin geliştirilmesinde özellikle iyonik denge parametrelerinin önemini vurgulamakta ve gelecek araştırmalar için kil mineralojisi ile mikrobiyal aktivitenin ortak etkilerinin incelenmesi gerektiğini işaret etmektedir.

5.1. Toprak Kalitesinin Değerlendirilmesi

Toprak kalitesinin belirlenmesi dinamik ve kalıtsal değişimin takibi, toprakların sürdürülebilirliği ve üretkenliğinin korunarak iyileştirilmesine fırsat oluşturmaktadır. Bitki verimliliği, doğrudan veya dolaylı olarak toprağın farklı fonksiyonlarını yerine getirme yeteneğine önemli ölçüde gereksinim duyar. Toprağın bu işlevleri optimum sınırlar içinde yerine getirmesi, toprak kalite değerlendirmesinin ana unsurudur (Doran ve Parkin 1994). Özellikle Amerika Birleşik Devletleri, Almanya, Birleşik Krallık, Avustralya, Kanada, Hollanda, Japonya ve Tayvan dahil olmak üzere tarımda gelişmiş uluslarda, kirlenmiş toprakların değerlendirilmesi ve iyileştirilmesi için çeşitli kriterler oluşturulmuştur (ICRCL 1987; USEPA 1989; Alloway 1990; Jacobs 1990, Tiller 1992; Ministry of Housing Netherlands 1994; Chen vd. 1996; Adriano vd. 1997; Chen 1998). Avrupa Birliği Komisyonu, 1997 yılında toprak kalitesinin korunmasının sürdürülebilir tarımsal kalitenin tanımlanmasında bir ön şart olduğunu belirtmiştir (Audsley vd. 1997). Toprak kalitesi değerlendirmeleri çiftlik yönetiminin olumsuz etkilerini zamanında fark etmemizi sağlayan bir değerlendirme biçimidir (Askari ve Holden 2015). Toprak kalitesi, konu ile ilgili uzmanların tanımı ile toprağın fonksiyonlarını yerine getirebilme kapasitesi olarak belirlenmiştir (Andrews vd. 2004).

Ekosistemdeki dinamik ve kalıtsal etkilerden dolayı; toprakların, bitkilerin yetişebilmesi için gerekli bütün fonksiyonları yerine getirebilmesi, uygulamalar arttıkça daha karmaşık bir düzeye geçmektedir (Govaerts vd. 2006). İlerleyen süreçte mevcut durumda kalıtsal fonksiyonlarını yerine getirebilme potansiyeli düşük olan mera arazilerinde de arazi bozulması ve biyolojik üretkenliğin geri dönüşü olmayacak bir hal alarak çoraklaşmaya dönmesi muhtemel bir durumdur (Acar, 2023).

Wander ve Bollero (2000), toprak kalitesinin geçmişten günümüze değerlendirilme yöntemlerini ve gelecekteki yönelimlerini kapsamlı bir şekilde incelemiştir. Makalede, toprak kalitesinin hem fiziksel, kimyasal hem de biyolojik bileşenlerinin entegre bir biçimde değerlendirilmesinin önemi vurgulanmıştır. Özellikle sürdürülebilir tarım uygulamalarının geliştirilmesinde toprak kalitesi göstergelerinin kritik rol oynadığı belirtilmiştir. Ayrıca, toprak kalitesinin dinamik bir kavram olduğu, çevresel faktörler ve arazi kullanımı değişiklikleriyle sürekli olarak etkilenebileceği üzerinde durulmuştur. Gelecekte, toprak kalitesi değerlendirmelerinin daha hassas, çok boyutlu ve teknolojik gelişmelerle desteklenen yöntemlerle yapılmasının gerekliliği öne çıkarılmıştır.

Konu uzmanları toprak kalitesinin belirlenmesi ve iyileştirilmesi için farklı modeller geliştirmişlerdir (Black, 1965, Andrews vd., 2004, Stevenson, 2005, Viscarra Rossel vd., 2006). Çalışmalarda toprak kalitesinin fiziksel, kimyasal ve biyolojik özelliklerinin birlikte değerlendirildiği minimum veri kümesinin (MDS) uzmanlar tarafından belirlenmesi, çalışmaların temelini oluşturmaktadır (Rezaei vd., 2006). Arazi kullanımı ve tarımsal uygulamalar nedeniyle toprak sağlığında meydana gelen değişiklikleri ölçmek ve değerlendirmek amacıyla Toprak Yönetimi Değerlendirme Çerçevesi (SMAF) (Cherubin vd., 2017), ilk akla gelen yöntemdir. (Nunes vd., 2020; Alaboz vd., 2022; Pacci vd., 2022; Jimenez vd., 2022; Gyawali vd., 2023; de Andrade Bonetti vd., 2023). SMAF modelinde arazi uygulamaları ve ekosistem hizmetleriyle bağlantılı toprak sağlığını değerlendirmek amacıyla fiziksel, kimyasal ve biyolojik toprak özelliğini araziye özgü nitelikler için doğrusal olmayan puanlama eğrileri kullanılmaktadır (Karlen vd., 2019).

Toprak kalite indeksinin hesaplanma yöntemlerinden gösterge skorlarının toplanması ve toplam gösterge sayısına bölünmesi ile elde edilen aşağıdaki eşitlik en çok tercih edilen basit eklemeli yöntemidir. (Andrews vd., 2004; Karlen vd., 2013; Mukherjee ve Lal, 2014). Toprak kalite indeksinin hesaplanmasında Eşitlik 1'deki formül kullanılmıştır.

Toprağın genel kalitesini ortaya koyma amacı ile indikatörlerin aldığı değerlerin tek bir indekse dâhil edilmesi amacıyla SMAF modeli, eklemeli indeks yöntemini kullanmaktadır. Eklemeli indeks hesabında söz konusu indikatörlerin tümünden ayrı ayrı gelen değer toplanmakta ve indikatör sayısına bölünerek ortalaması belirlenmekte, elde edilen sonuç 100 ile çarpılarak toprağın toprak kalitesi yüzde olarak ifade edilmektedir. Toprak kalite skorlamasına yönelik sınıflarda elde edilen değerler 40'ın altında ise söz konusu toprakların kalitesi çok düşük, 40-55 arasında ise düşük, 55-70 arasında ise orta, 70-85 arasında yüksek ve > 85 ise çok yüksek olarak değerlendirilmektedir (Gugino vd., 2009). Literatürde farklı sınıflamalar olmakla birlikte, genelde (,00-,30) zayıf düzeyde, (,31-,49) orta düzeyde, (,50-,69) güçlü düzeyde, (,70-,100) çok güçlü düzeyde ilişki olduğu şeklinde yorumlanmaktadır (Tavşancıl, 2005).

$$TKI = \left[\frac{\sum_{i=1}^n X_i}{n} \right] \times 100 \quad (5.1)$$


Eşitlikteki; Xi: İndikatörün toplam skoru, n: İndekste yer alan gösterge sayısı, TKI: Toprak kalite indeksi.

5.1.1. Toprak Fiziksel Göstergeleri

Doran ve Parkin (1994), toprak kalitesinin değerlendirilmesi için bazı fiziksel göstergeler belirlemişlerdir. Bu göstergeler; toprak tekstürü, toprak derinliği, üst toprak veya köklenme, sızma, toprak hacim yoğunluğu ve su tutma kapasitesini kapsar. Hseu ve ark. (1999) Tayvan topraklarının kalitesinin belirlenmesinde ilave birkaç parametre seçmiştir, seçilen fiziksel göstergeler; A horizonunun derinliği, toprak tekstür sınıfları veya % kil, silt ve kum içeriği, hacim yoğunluğu, kullanılabilir su içeriği yüzdesi ve 30 cm derinlikte agregat stabilitesini kapsamaktadır. Toprak kalitesinin belirlenmesinde, toprağa suyun sızma hızı ve hidrolik iletkenlik ölçümleri önemlidir, ancak açık arazi üretimindeki saha genişliği ve çeşitlilik sağlıklı veri elde etmeyi oldukça zorlaştırmaktadır (Cameron vd., 1998).

Beare vd. (1997) Toprak kalitesinin fiziksel göstergelerinin belirlenmesinde; Toprak Tekstürünün; gözeneklilik, sızma ve mevcut su içeriği için önemli parametre olduğunu, Hacim yoğunluğunun; sızma hızı ve hidrolik iletkenlik için önemli parametre olduğunu, Agregat stabilitesinin; toprak erozyon direnci ve organik madde

içeriği için önemli parametre olduğunu belirtmişlerdir.



Şekil 5.1. Fiziksel Toprak Kalite Haritası


Çalışma alanına ait fiziksel toprak kalite haritası Şekil 5.1’ de verilmiştir. Alanın toprak kalitesi 43-88 arasında değişiklik göstermekle beraber ortalama 60 kalite skoru skor cetvelinde 55-70 kalite skorları arasında olmasından dolayı ‘orta kalite’ olarak tanımlanmıştır. Alanın güney kısmının fiziksel toprak kalite durumunun alanın diğer kısımlarına göre daha yüksek olduğu belirlenmiştir. Alanın kuzey kısmında yine yer yer yüksek kaliteye sahip alanlar olmakla beraber genel olarak orta kaliteye sahip olduğu gözlemlenmektedir.

Fiziksel kalite skorunun orta kalitede olmasının sebepleri arasında toprak tekstüründeki değişikliklere bağlı olarak, kum ve kil içeriğinin farklı olması; topraktaki kum içeriğinin yüksek olduğu bölgelerde agregat yapısının iyi gelişim gösterememiş olması ve yarayışlı su içeriğinin az olması, kil içeriğinin yüksek olduğu kısımlarda ise hidrolik iletkenliğin düşük olması kalite skorunu etkilemiştir. Toprak agregatlaşması tohum ve toprak arasındaki bağlantı, ürünün kök gelişimi ve havalanması, toprak hidrolik iletkenliği ile ürünün gelişimini devam ettirebilmesi

bakımından etkilidir (Dinel vd., 1991). Toprakların geçirgenliğini ve topraklarda bitki besin elementi hareketini kontrol eden önemli fiziksel bir özellik olarak görülen toprak hidrolik iletkenliği, topraklar içinde büyük farklılık oluşturmaktadır (Kırda ve Sariyev 2002, Sariyev vd., 2020).

5.1.2. Toprak Kimyasal Göstergeleri

Toprak kalitesinin değerlendirilmesi için toprağın kimyasal özelliklerinin verileri gereklidir. Kimyasal göstergeler içerisinde; toprak pH' sı, elektrik iletkenliği (Ec) ve ekstrakte edilebilir mevcut N, P ve K önemli göstergeler olarak kabul edilir (Doran ve Parkin 1994). Hseu vd. (1999), Tayvan topraklarının kalitesini değerlendirmek için bazı kimyasal göstergeler belirlediler. Belirledikleri göstergeler şunlardır: toprak pH' sı, elektrik iletkenliği (Ec), organik karbon, ekstrakte edilebilir mevcut N, P ve K, ekstrakte edilebilir mevcut mikro elementler (Cu, Zn, Cd, ve Pb).




Şekil 5.2. Kimyasal Toprak Kalite Haritası

Çalışma alanına ait kimyasal toprak kalitesi haritası Şekil 5.2' de verilmiştir. Alanın kimyasal toprak kalitesi 50-57 arasında değişiklik göstermekle beraber ortalama 54 kalite skoru sonucu ile 40-55 kalite skorları arasında olması nedeni ile

kimyasal toprak kalitesi ‘düşük’ olarak tanımlanmıştır. Solhan Ovasının kimyasal kalite skorunun düşük kalitede olmasının sebepleri arasında; Kireç ve Ec skorlarının düşük olması yüksek ve orta skora sahip katyon değişim kapasitesi ve değişebilir katyon yüzdesi skorlarını etkisi belirleyici olmuştur.

5.1.3. Toprak Biyolojik Göstergeleri

Biyolojik göstergelerin en önemlisi toprak solunum oranıdır. Toprak solunum oranı, organik maddenin ayrışması sonucu oluşan karbondioksit dönüşümünün saptanmasıdır. Toprak solunum oranı ile toprağın biyolojik verimliliği doğrusal bir eğri izler. Biyolojik parametrelere etki eden diğer faktörler; nem, sıcaklık ve organik madde oranıdır. Toprak havasının yüzde 60'nın nem olması durumunda biyolojik faktörler optimum düzeyde olur. Sıcaklık artışı ile biyolojik fonksiyonlar doğru orantılıdır. Bu aktiviteler belirli sıcaklıkta maksimuma ulaşır. Tarım ilaçları topraktaki mikroorganizmaların ölmesine neden olur. Bu durumda toprak solunum oranının azalmasına sebep olur (Mirsal, 2008). Doran ve Parkin (1994), toprak kalitesinin değerlendirilmesi için bir dizi biyolojik parametreleri belirlemişlerdir. Mikrobiyal karbon ve azot, potansiyel mineralize edilebilir azot, su içeriği, toprak sıcaklığı ve toprak solunumu veri setini benimsemişlerdir. Hseu ve ark. (1999) ise topraklarının kalitesinin değerlendirilmesi için mikrobiyal biyokütlede bulunan N, C ve P' un potansiyel mineralizasyonu, toprak solunumu, solucan sayısı ve mahsul verimini biyolojik göstergeler olarak seçmiştir. Biyolojik göstergeler, toprak bozulması ve kirlenmesinin hassas verileridir. Biyolojik kalitenin belirleyici göstergelerden ikisi mikrobiyal biyokütle ve mikrobiyal aktivitedir (Cameron vd. 1998). Isparta Uygulamalı Bilimler Üniversitesi kampüsü içerisinde yapılan çalışmada, SMAF modelinden yararlanarak toprakların fiziksel, kimyasal, biyolojik ve genel kalite durumlarının belirlenmesi çalışmasında genel kalite skorlarındaki düşüklüğün biyolojik kalite indikatörlerinden kaynaklandığı saptanmıştır (Alaboz vd. 2022).




Şekil 5.3. Biyolojik Toprak Kalite Haritası

Çalışma alanına ait biyolojik toprak kalitesi haritası Şekil 5.3’ te verilmiştir. Alanın biyolojik toprak kalitesi 40-56 arasında değişiklik göstermekle beraber, ortalama 48 kalite skoru ile 40-55 kalite skorları arasında olduğu için toprak kalitesi ‘düşük’ olarak tanımlanmıştır. Çalışma alanının kuzeyinin güneyine göre daha yüksek kaliteye sahip olduğu, ancak genel olarak çalışma alanının biyolojik kalitesinin düşük olduğu belirlenmiştir.

5.1.4. Genel Toprak Kalitesi

Topraklar dinamikdir ve bu nedenle sürekli olarak değişkendirler, ekolojik veya yönetim güçlerinin etkisiyle bozunur, sürdürülür veya iyileşir (Larson and Pierce, 1991). Toprak kalitesi değerlendirme yöntemlerinde temel vurgu “dinamik toprak kalitesi” üzerinedir. Dinamik toprak kalitesi “genetik toprak kalitesinden ziyade” mevcut ve geçmiş amenajman kararlarının etkilerini göstermektedir (Karlen vd. 2008). Fiziksel, kimyasal ve biyolojik özelliklerin kalitesi toprağın kalitesini oluşturur. Tarım bağlamında sürdürülebilirlik önemli ölçüde toprağın fiziksel, kimyasal ve biyolojik özelliklerini iyileştirmeye bağlı olarak toprak, bitki ve arazi yönetimi ile ilgilidir (Schachtschabel vd. 2007). SMAF modeli kullanılarak toprak kalite özelliklerinin belirlendiği çalışmada; ayçiçeği tarımı yapılan toprakların kimyasal kalite indeksinin düşük, fiziksel toprak kalitesinin orta, biyolojik kalitenin

ise yüksek olduğu, toplam kalite indeks değerlerinin ise yüksek düzeyde olduğu belirlenmiştir (Pacci ve Dengiz. 2023).



Şekil 5.4. Genel Toprak Kalite Haritası

Çalışma alanına ait genel toprak kalitesi haritası Şekil 5.4’ te verilmiştir. Alanın toprak kalitesi 50-62 arasında değişiklik göstermekle beraber ortalama 56 kalite skoru ile 55-70 kalite skorları arasında olduğu için ‘orta kalite’ olarak tanımlanmıştır. Solhan Ovasının kuzeyi ile güneyinin genel toprak kalitesinin çalışma alanının ortasına göre daha iyi olduğu, genel olarak tüm alanın orta kaliteye sahip olduğu haritada da gözlemlenmektedir.

5.2. Yapay Sinir Ağları ile Toprak Özelliklerinin İstatistiksel Analiz Sonuçları

5.2.1. Yapay Sinir Ağları ile Değişebilir Katyon Yüzdesi Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları

Solhan Ovası topraklarının Değişebilir Katyon Yüzdesi verilerinin yapay sinir ağları ile tahmin edilmesi amacıyla değişik iterasyon sayıları, farklı ağ yapılarında ve farklı eğitim algoritmaları (LM, SCG ve BR) eğitilerek oluşturulan modeller incelenmiş ve en iyi tahmin yeteneği oluşturan modeller belirlenerek sonuçlar Çizelge 5.1’ de belirtilmiştir. Çizelge 5.1’ e göre en yüksek R^2 değerini ve en düşük

MAE ve RMSE değerini veren modelin çift gizli katmanlı ve 2 girdi değişkeni kullanılan (2-7-5-1) ağ yapısında 75 iterasyon sayısında ulaşılmıştır.

Çizelge 5.1. Değişebilir Katyon Yüzdesi tahmini için oluşturulan modellerin istatistiksel analiz sonuçları

Eğitim Algoritması	Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
				R ²	MAE	RMSE	R ²	MAE	RMSE
LM		(2-7-5-1)	75	0.85	1.705	2.255	0.86	1.752	2.278
SCG	Ec, Kil	(2-12-11-1)	50	0.70	0.081	0.103	0.92	0.048	0.061
BR		(2-28-25-1)	100	0.75	0.068	0.092	0.94	0.039	0.057

5.2.2. Yapay Sinir Ağları ile Katyon Değişim Kapasitesi Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları

Solhan Ovası topraklarının Katyon Değişim Kapasitesi (KDK) verilerinin yapay sinir ağları ile tahmin edilmesi amacıyla değişik iterasyon sayıları, farklı ağ yapılarında ve farklı eğitim algoritmaları (LM, SCG ve BR) eğitilerek oluşturulan modeller incelenmiş ve en iyi tahmin yeteneği oluşturan modeller belirlenerek sonuçlar Çizelge 5.2’de belirtilmiştir. Çizelge 5.2’ ye göre en yüksek R² değerini ve en düşük MAE ve RMSE değerini veren modelin çift gizli katmanlı ve 2 girdi değişkeni kullanılan (2-26-2-1) ağ yapısında 50 iterasyon sayısında ulaşılmıştır.

Çizelge 5.2. Katyon Değişim Kapasitesi tahmini için oluşturulan modellerin istatistiksel analiz sonuçları

Eğitim Algoritması	Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
				R ²	MAE	RMSE	R ²	MAE	RMSE
LM		(2-26-2-1)	50	0.73	0.439	0.533	0.62	0.414	0.630
SCG	Ec, Kil	(2-28-16-1)	75	0.50	0.134	0.170	0.79	0.096	0.115
BR		(2-2-24-1)	25	0.45	0.145	0.183	0.74	0.099	0.110

5.2.3. Yapay Sinir Ağları ile Tarla Kapasitesi Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları

Solhan Ovası topraklarının Tarla Kapasitesi verilerinin yapay sinir ağları ile tahmin edilmesi amacıyla değişik iterasyon sayıları, farklı ağ yapılarında ve farklı eğitim algoritmaları (LM, SCG ve BR) eğitilerek oluşturulan modeller incelenmiş ve en iyi tahmin yeteneği oluşturan modeller belirlenerek sonuçlar Çizelge 5.3’ te belirtilmiştir. Çizelge 5.3’ e göre en yüksek R² değerini ve en düşük MAE ve RMSE değerini veren modelin çift gizli katmanlı ve 2 girdi değişkeni kullanılan (2-6-6-1) ağ

yapısında 75 iterasyon sayısında ulaşılmıştır.

Çizelge 5.3. Tarla Kapasitesi tahmini için oluşturulan modellerin istatistiksel analiz sonuçları

Eğitim Algoritması	Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
				R ²	MAE	RMSE	R ²	MAE	RMSE
LM	Ec, Kil	(2-6-6-1)	75	0.97	0.560	1.012	0.96	0.610	1.094
SCG		(2-24-16-1)	25	0.31	0.135	0.175	0.73	0.105	0.125
BR		(2-10-6-1)	75	0.43	0.135	0.159	0.76	0.101	0.114

5.2.4. Yapay Sinir Ağları ile Solma Noktası Tahmini için Oluşturulan Modellerin İstatistiksel Analiz Sonuçları

Solhan Ovası topraklarının Solma Noktası verilerinin yapay sinir ağları ile tahmin edilmesi amacıyla değişik iterasyon sayıları, farklı ağ yapılarında ve farklı eğitim algoritmaları (LM, SCG ve BR) eğitilerek oluşturulan modeller incelenmiş ve en iyi tahmin yeteneği oluşturan modeller belirlenerek sonuçlar Çizelge 5.4’ te belirtilmiştir. Çizelge 5.4’ e göre en yüksek R² değerini ve en düşük MAE ve RMSE değerini veren modelin çift gizli katmanlı ve 2 girdi değişkeni kullanılan (2-19-24-1) ağ yapısında 50 iterasyon sayısında ulaşılmıştır.

Çizelge 5.4. Solma Noktası tahmini için oluşturulan modellerin istatistiksel analiz sonuçları

Eğitim Algoritması	Girdi	Ağ Yapısı	İterasyon sayısı	Eğitim			Test		
				R ²	MAE	RMSE	R ²	MAE	RMSE
LM	Ec, Kil	(2-19-24-1)	50	0.99	0.003	0.004	0.99	0.003	0.004
SCG		(2-22-11-1)	50	0.28	0.144	0.184	0.80	0.081	0.104
BR		(2-25-10-1)	100	0.37	0.133	0.169	0.86	0.058	0.069

5.2.5. Yapay Sinir Ağı Modellemesi

Yapay Sinir Ağları (YSA) çeşitli alanlarda başarıyla uygulanmış ve karmaşık ilişkileri modellemek için etkili bir araç olduğu kanıtlanmıştır. Örneğin, manzara değerlendirmesi alanında, Aitkenhead ve Dyer (2007) ve Kuplich (2009) bu teknolojinin potansiyelini göstermiştir. Benzer şekilde, YSA'nın toprak mikrobiyal biyokütlesinin manzara ölçeğinde analizi (Lentzsch vd. 2005), topraktaki endokrin bozucu bileşiklerin konsantrasyonlarının tahmini (Aitkenhead ve diğerleri, 2014), toprak sıcaklığının tahmini (Öztürk vd. 2011) ve arazi gözlemlerine dayalı toprak

kimyasal bileşiminin ve diğer toprak parametrelerinin belirlenmesi (Aitkenhead vd. 2012) gibi çalışmalarda başarılı sonuçlar sağladığı gösterilmiştir.

Ek olarak, YSA'nin etkinliği ürün verimi tahmini (Paswan ve Begum, 2013) ve toprak N emisyonlarının modellenmesi (Delon vd. 2007) gibi farklı uygulamalarda kanıtlanmıştır. Orta İran'da yürütülen bir çalışmada, Amini vd. (2005) kation değişim kapasitesi, toprak organik maddesi ve kil içeriği gibi parametreleri YSA kullanarak tahmin etmiştir. Bu çalışma, YSA modellerinin değişkenler arasındaki doğrusal olmayan ilişkileri yakalamak için geleneksel yöntemlerden daha uygun olduğunu ortaya koymuştur. Bu bulgular, YSA 'nin toprak bilimi ve peyzaj analizi gibi alanlarda geniş bir uygulama yelpazesine sahip olduğunu göstermektedir.

Bu çalışmada, toprak kalitesini belirlemek için yapay sinir ağları (YSA) kullanılmıştır. YSA'nın doğrusal olmayan ilişkileri modelleme yeteneği, toprak analizi gibi çok değişkenli problemler için etkili bir çözüm sunmaktadır. Bu çalışmada, Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Scaled Conjugate Gradient (SCG) algoritmaları kullanılarak yüksek doğrulukta tahmin modelleri geliştirilmiştir. Ek olarak, 0-30 nöron aralığına sahip tek ve çift gizli katman mimarileri denendi ve Ec ve kil içeriği giriş verisi olarak kullanıldı.

5.2.6. Öğrenme Algoritmaları

Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Scaled Conjugate Gradient (SCG) algoritmaları farklı hiperparametre optimizasyonu gerektiren yöntemlerdir. LM algoritması hızlı yakınsaması ile öne çıkarken, BR algoritması aşırı öğrenmeyi önleme yeteneği ile öne çıkmaktadır. SCG algoritması büyük ölçekli veri kümelerinde hesaplama verimliliği sağlamıştır. Her algoritma için hiperparametreler (örneğin öğrenme oranı, düzenleme parametreleri) en iyi performansı elde etmek için optimize edilmiştir.

5.2.7. Gizli Katman Sayısı ve Nöron Sayısı

Gizli katman sayısı ve her katmandaki nöron sayısı, modelin karmaşıklığını ve öğrenme kapasitesini doğrudan etkileyen kritik hiperparametrelerdir. Bu çalışmada, 25-100 nöron aralığında tek ve çift gizli katman mimarileriyle kapsamlı deneyler yürüttük. Sonuçlar, çift gizli katman mimarisinin, özellikle 50 nöronla daha karmaşık ilişkileri modelleme yeteneğiyle daha yüksek doğruluk oranları sağladığını göstermektedir. Ancak, nöron sayısının artırılması, modelin eğitim süresini ve hesaplama maliyetini de artırmıştır. Bu nedenle, model karmaşıklığı ve performans

arasında bir takas yapılması gerekmektedir.

5.2.8. Giriş Verilerinin Etkisi

Çalışmada, Ec ve kil içeriği giriş verisi olarak kullanılmıştır. Bu parametreler, toprak kalitesini belirlemede kritik öneme sahiptir. Analiz, bu giriş verilerinin YSA modellerinin performansını önemli ölçüde etkilediğini göstermiştir. Özellikle kil içeriği, toprağın fiziksel ve kimyasal özelliklerini belirlemede önemli bir rol oynamıştır.

5.2.9. Genel Değerlendirme

Yapay sinir ağları, toprak kalitesi tahmininde yüksek doğruluk oranları sağlamıştır. Ancak, farklı algoritmaların performansı, gizli katman sayısına, nöron sayısına ve giriş verilerinin doğasına göre değişmiştir. Bu çalışma, özellikle çift gizli katman mimarisi ve 50 nöronuyla LM algoritmasının toprak kalitesi tahmininde en iyi sonuçları verdiğini ortaya koymuştur. Gelecekteki çalışmalarda, daha büyük ve daha çeşitli veri kümeleri üzerinde testler yürütülerek modellerin genelleme yeteneklerinin daha fazla araştırılması önerilmektedir. Ayrıca, farklı optimizasyon tekniklerinin ve hibrit modellerin kullanılması model performansını daha da iyileştirebilir. Hiperparametre optimizasyonu, yapay sinir ağlarının performansını belirleyen en önemli adımlardan biridir. Bu çalışmada, gizli katman sayısı, nöron sayısı, öğrenme algoritması ve aktivasyon fonksiyonları gibi hiperparametrelerin optimize edilmesiyle yüksek doğruluk oranları elde edilmiştir. Ancak, hiperparametre optimizasyonunun zaman alıcı ve yoğun bir süreç olduğu da gözlemlenmiştir. Gelecekteki çalışmalarda, otomatik optimizasyon tekniklerinin kullanılması ve daha büyük veri kümeleri üzerinde testler yapılması önerilmektedir.

6. SONUÇLAR

Bingöl ili Solhan İlçesi'nde yer alan Solhan Ovası'ndaki tarım arazilerinin toprak kalite durumunu belirlemeye yönelik yapılan çalışmada, toprak kalitesinin değerlendirilmesinde toprakların fiziksel, kimyasal ve biyolojik kalite değerlerine dayalı SMAF modeli ve eklemeli indeks yöntemi kullanılmıştır. Elde edilen bulgulara göre, çalışma alanındaki zirai üretim faaliyetleri göz önüne alındığında, hesaplanan fiziksel kalite skoru orta, kimyasal kalite skoru düşük, biyolojik kalite skoru ise düşük olarak belirlenmiştir. Sonuç olarak, genel kalite skoru orta düzeyde değerlendirilmiştir. Fiziksel toprak parametreleri arasında, topraktaki kum içeriğinin yüksek olması ve yarayışlı su miktarının düşük olması; kimyasal kalite parametrelerinde kireç ve elektriksel iletkenlik (Ec) skorlarının düşük olması; biyolojik kalite parametresi açısından ise organik madde miktarının yetersizliği etkili olmuştur. Bu değerlendirmeler ışığında, Solhan Ovası'ndaki zirai üretimin sürdürülebilirliğini sağlamak amacıyla, toprak kalitesinin yıllar içinde izlenmesi ve iyileştirilmesi gerekliliği ortaya çıkmaktadır. Ayrıca, sürdürülebilir tarım için toprak kalitesini artıracak arazi yönetim uygulamalarının hayata geçirilmesi büyük önem taşımaktadır.

Çalışma alanındaki arazi yöneticilerinin uyguladığı farklı yönetim stratejileri (sulama, gübreleme, ilaçlama, toprak işleme vb.), toprak kalite parametrelerinde bölgesel farklılıklar oluşturmaktadır. Bu değişiklikler, ürün verimliliğini doğrudan etkileyebilir. Örneğin, toprak fiziksel kalite değerinin yüksek olması, bitki köklerinin rahat bir şekilde büyümesine ve besin alımının artmasına yardımcı olurken, düşük fiziksel kalite ise toprak sıkışması nedeniyle besin maddelerinin hareketini engeller ve kök gelişimini kısıtlar. Ayrıca, sıkışmış topraklar kök bölgesindeki hava ve gaz değişimini zorlaştırarak denitrifikasyon ya da toksik gaz birikimi gibi besin kayıplarına neden olabilir. Kimyasal kalite açısından ise, besin maddelerinin aşırı kullanımı, bitki zehirlenmesine yol açabileceği gibi, eksiklik durumunda da bitki büyümesini olumsuz etkileyebilir. Biyolojik kalite değerinin yüksek olması, toprakta besin döngüsünü sağlayan mikroorganizmaların varlığını gösterir; bu organizmalar, organik maddeleri ayrıştırarak besinleri bitkiler için kullanılabilir hale getirir.

Ülkemizde her alanda olduğu gibi toprak biliminde de teknolojik gelişmeler etkin bir şekilde kullanılmaktadır. Artan dünya nüfusu ile birlikte insanlık için gıda ihtiyacı büyük önem taşımaktadır. Bu gereksinimleri karşılamak için tarımsal üretkenliği sürekli artırılması kritik bir ihtiyaç haline gelmiştir.

Tarımsal üretkenliği artırmak için yapılması gereken önemli çalışmalardan biri de toprak sağlığı ve kalitesinin doğru bir şekilde belirlenmesidir. Mevcut teknolojiler kullanılarak minimum maliyetle maksimum fayda sağlanabilir ve toprak kalitesi ortaya çıkarılabilir. Bu, bitkilerin büyüme süreçleri boyunca ihtiyaç duyduğu besin maddelerinin en uygun şekilde ve doğru miktarda uygulanmasını sağlamak için gereklidir. Böylece tarımsal üretimde girdi maliyetleri ekonomik açıdan düşürülebilir ve yüksek doğrulukta tahminler yapılarak çevre dostu ve sürdürülebilir uygulamalar benimsenebilir. Bu şekilde aşırı gübrelemeden kaynaklanabilecek yeraltı suyu ve toprak bozulması önlenir. Özellikle geniş alanlarda veya zaman kısıtlı durumlarda önemli bir avantaj sağlayabilir.

Yapay sinir ağlarının başarılı bir şekilde çalışabilmesi için yüksek kaliteli, kapsamlı ve doğru veri kümelerine ihtiyaç duyulduğu belirlenmiştir. Bu, veri toplama ve ön işleme aşamalarının ne kadar kritik olduğunu ortaya koymuştur.

Ancak bazı durumlarda eksik veya yanlış toprak verileri modelin doğruluğunu olumsuz yönde etkileyebilir. Bu, veri kümelerinin kalitesinin iyileştirilmesini gerektirir. YSA modelinin doğruluğunu artırmak için daha büyük bir veri kümesi kullanılmalıdır. Bu, farklı coğrafi bölgelerden, iklim koşullarından ve tarımsal yöntemlerden toprak örneklerini içeren daha kapsamlı veriler anlamına gelir. Ayrıca, toprak verilerinin düzenli aralıklarla güncellenmesi modelin doğruluğunu artıracaktır.

YSA, toprak kalitesini belirlemede farklı fiziksel (örn. toprak yapısı) ve kimyasal (örn. pH, besin maddeleri) parametreleri entegre etme kapasitesine sahiptir. Bu, geleneksel yöntemlerle ölçülmesi zor olan birden fazla faktörün değerlendirilmesinde büyük bir avantaj sağlar.

Aynı zamanda, YSA 'nin çok boyutlu verileri analiz etme yeteneği sayesinde, toprak kalitesinin daha kapsamlı ve doğru tahminleri yapılabilir.

Yapay Sinir Ağları (YSA), geleneksel yöntemlere kıyasla toprak kalitesi tahmininde daha hızlı ve daha doğru sonuçlar sağlayabilir. Bu, özellikle hızlı kararlar almak ve tarıma müdahale etmek isteyen çiftçiler için çok değerli olabilir.

7. ÖNERİLER

Solhan Ovası'ndaki toprakların fonksiyonlarını sürdürebilmesi ve iyileştirilmesi için, fiziksel, kimyasal ve biyolojik kalite parametrelerinin uygun düzeyde olması gerekmektedir. Bu nedenle, toprak kalitesinin artırılması için yapılan arazi yönetim uygulamaları, sürdürülebilir tarım ve toprak sağlığının korunması açısından büyük önem taşımaktadır.

Özellikle toprak kalitesinin düşük olduğu bölgelerde ekim nöbeti uygulamaları ve ahır gübresi gibi doğal gübrelerin kullanılması, toprak kalitesinin kısa sürede iyileşmesine katkı sağlayacaktır. Aksi takdirde, kötü arazi yönetim uygulamaları bu toprakların daha da kötüleşmesine yol açacaktır. Yapılan bu çalışma, SMAF modelinin toprak kalitesinin değerlendirilmesinde etkili bir araç olduğunu ve çiftçilerin, arazi yöneticilerinin ve diğer paydaşların, sürdürülebilir arazi kullanımı ve toprak sağlığını iyileştirme yönünde daha bilinçli ve etkili kararlar almasına yardımcı olabileceğini göstermektedir. Ayrıca, toprak kalitesinin ürün kalitesiyle doğrudan ilişkili olduğu gibi, sulama suyu kalitesi, gübre kullanımı ve arazi yönetim uygulamaları gibi faktörlerin de önemli bir rol oynadığı unutulmamalıdır. Türkiye'de Tarım ve Orman Bakanlığı tarafından uygulanan İyi Tarım Uygulamaları ve ÇATAK Projesi gibi desteklerle, sürdürülebilir tarım uygulamalarına yönelen arazi yöneticilerine ek tarımsal destekler verilerek, toprak kalitesinin artırılmasına katkı sağlanmalıdır.

Yapay Sinir Ağları'nın daha doğru sonuçlar verebilmesi için kullanılan modelin parametrelerinin optimize edilmesi önerilir. Bu, hiperparametre ayarlarının ve model yapısının (örneğin katman sayısı, nöron sayısı) iyileştirilmesi gerektiği anlamına gelir. Ayrıca, modelin aşırı uyumunu önlemek için daha büyük veri kümeleri ve doğrulama yöntemleri kullanılmalıdır.

Yapay Sinir Ağları'nın toprak kalitesini belirlemede kullanılmasına ek olarak, modelin farklı çevresel ve tarımsal parametrelerle entegre edilmesi önerilebilir. Örneğin, modeli su yönetimi, gübreleme stratejileri veya bitki sağlığı ile ilgili verilerle daha kapsamlı hale getirmek, toprak yönetimi konusunda daha etkili kararlar alınmasını sağlayabilir.

Laboratuvar ortamlarında kimyasal maddeler kullanılarak doğrudan toprak özelliklerini ölçmek yerine yapılan analizlerin çevresel hasar potansiyeli, bu tür analizler yerine yapay sinir ağı (YSA) modellerinin kullanılmasını daha uygun hale

getirir. Ayrıca, bu tür analizler, toprak kalitesinin korunması ve sürdürülebilir yönetim uygulamalarının yönlendirilmesi açısından tarımsal üretimde aktif rol oynayan çiftçiler, arazi yöneticileri ve uzmanlar için oldukça değerlidir. Çiftçiler ve arazi yöneticileri için YSA kullanımını yaygınlaştırmak amacıyla eğitimler düzenlenebilir. Yapay zeka ve makine öğrenmesi tekniklerinin tarımda nasıl yararlı olabileceği konusunda bilgilendirme çalışmaları yapılmalıdır.

KAYNAKLAR

- Abbaspour, A., & Baramakeh, L. (2006). Application of principle component analysis artificial neural network for simultaneous determination of zirconium and hafnium in real samples. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 64(2), 477-482. <https://doi.org/10.1016/j.saa.2005.07.050>
- Acar, M. (2023). *Aşağı Seyhan ovasında toprak kalitesinin değerlendirilmesi ve izlenmesinde amenajmana hassas indikatörlerin belirlenmesi* [Master's thesis, Çukurova University].
- Adriano, D. C., Albright, J., Whicker, F. W., Iskandar, I. K., & Sherony, C. (1997). Remediation of soils contaminated with metals and radionuclide-contaminated soils. In *Remediation of soils contaminated with metals* (pp. 27-46). Science Reviews.
- Adriano, D. C., Chlopecka, A., Kaplan, D. I., Clijsters, H., & Vangronsveld, J. (1997). *Soil contamination and remediation: Philosophy, science, and technology*. In Contaminated soils (pp. 465-504).
- Aitkenhead, M. J., Aitkenhead-Peterson, J. A., McDowell, W. H., Smart, R. P., & Cresser, M. S. (2007). Modelling DOC export from watersheds in Scotland using neural networks. *Computers & Geosciences*, 33(4), 423-436. <https://doi.org/10.1016/j.cageo.2006.08.008>
- Aitkenhead, M. J., & Dyer, R. (2007). Improving land cover classification using recognition threshold neural networks. *Photogrammetric Engineering & Remote Sensing*, 73(4), 413-421. <https://doi.org/10.14358/PERS.73.4.413>
- Aitkenhead, M. J., Coull, M. C., Towers, W., Hudson, G., & Black, H. I. J. (2012). Predicting soil chemical composition and other soil parameters from field observation using a neural network. *Computers and Electronics in Agriculture*, 82, 108-116. <https://doi.org/10.1016/j.compag.2011.11.008>
- Aitkenhead, M. J., Rhind, S. M., Zhang, Z. I., Kyle, C. E., & Coull, M. C. (2014). Neural network integration of field observations for soil endocrine disruptor characterization. **Science of The Total Environment*, 485-486*, 240-248. <https://doi.org/10.1016/j.scitotenv.2014.03.065>
- Akbarzadeh, A., & Mehrjardi, R. T. (2010). Comparison of geostatistical methods for estimation of some soil properties in arid and semi-arid region of Iran. *Journal of Agricultural Science and Technology*, *12*(2), 241-252.
- Alaboz, P., Dengiz, O., Pacci, S., Demir, S., & Türkay, C. (2022). Determination of the effect of different organic fertilizers applications on soil quality using the SMAF model. *Yuzuncu Yıl University Journal of Agricultural Sciences*, 32(1), 21-32.
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop evapotranspiration: Guidelines for computing crop water requirements* (FAO Irrigation and Drainage Paper No. 56). Food and Agriculture Organization of the United

Nations.

- Alloway, B. J. (1990). *Heavy metals in soils*. Blackie and Son Ltd.
- Amini, M., Abbaspour, K. C., Khademi, H., Fathianpour, N., Afyuni, M., & Schulin, R. (2005). Neural network models to predict cation exchange capacity in arid regions of Iran. *European Journal of Soil Science*, 56(6), 748-757. <https://doi.org/10.1111/j.1365-2389.2005.00728.x>
- Andrews, S. S., Karlen, D. L., & Cambardella, C. A. (2004). The Soil Management Assessment Framework: A quantitative soil quality evaluation method. *Soil Science Society of America Journal*, 68(6), 1945-1962. <https://doi.org/10.2136/sssaj2004.1945>
- Andrews, S. S., Karlen, D. L., & Cambardella, C. A. (2002). The soil management assessment framework: A quantitative soil quality evaluation method. *Soil Science Society of America Journal*, 66(3), 825-833.
- Anonymous. (2015a). *Bingöl Province climate data*. Turkish Meteorological Service.
- Anonymous. (2018). *Neural network training and algorithms: Levenberg–Marquardt*. MATLAB Documentation.
- Anonymous. (2022). UNICEF. <https://www.unicef.org> (Accessed April 27, 2023)
- Anonymous. (2015b). *Bingöl Meteorological Station Directorate: 33 years of climate data for Bingöl province*.
- Armstrong, M. (1998). *Basic Linear Geostatistics*. Springer.
- Armstrong, R. A. (2014). When to use the Bonferroni correction. *Ophthalmic and Physiological Optics*, 34(5), 502-508.
- Askari, M. S., & Holden, N. M. (2015). Quantitative soil quality indexing of temperate arable management systems. *Soil & Tillage Research*, 150, 57-67. <https://doi.org/10.1016/j.still.2015.01.010>
- Audsley, E., Alber, S., & Gemeinschaften, E. (1997). *Harmonisation of environmental life cycle assessment for agriculture* (Report No. 139). European Commission, DG VI Agriculture.
- Audsley, E., Stacey, K., Parsons, D. J., & Williams, A. G. (1997). *Harmonisation of environmental life cycle assessment for agriculture*. European Commission.
- Avcı, V., Esen, F., & Kıranşan, K. (2018). Physical Geography Characteristics of Bingöl Province. *Journal of Bingöl Research*, 4(2), 9-40.
- Aydemir, S., & Şenol, H. (2018). Digital mapping of soil classes using Random Forest in Central Anatolia. *Catena*, 165, 352-364.
- Aydemir, S., et al. (2019). Development of national soil database system for Turkey. *Journal of Environmental Management*, 241, 502-515.
- Aydemir, S., Karaca, S., & Öztürk, H.S. (2020). Integrated soil quality assessment using analytic hierarchy process. *Geoderma*, 375, 114483.

- Ayers, R. S., & Westcot, D. W. (1985). *Water quality for agriculture* (FAO Irrigation and Drainage Paper No. 29 Rev. 1). Food and Agriculture Organization of the United Nations.
- Bai, J., Cui, B., Chen, B., Zhang, K., Deng, W., Gao, H., & Xiao, R. (2011). Spatial distribution and ecological risk assessment of heavy metals in surface sediments from a typical plateau lake wetland, China. *Ecological Modelling*, 222(2), 301-306. <https://doi.org/10.1016/j.ecolmodel.2010.07.021>
- Banimahd, M., Yasrobi, S. S., & Woodward, P. K. (2005). Artificial neural network for stress-strain behavior of sandy soils. *Computers and Geotechnics*, 32, 377–386.
- Battiti, R. (1992). First- and second-order methods for learning: Between steepest descent and Newton's method. *Neural Computation*, 4(2), 141-166.
- Bayram, M., Günal, H., & Özgöz, E. (2015). The importance of soil quality assessments in determining sustainable tillage methods. *Yüzüncü Yıl University Journal of Agricultural Sciences*, 25(3), 337–346.
- Bayramoğlu, Z., Demir, Y., & Öztürk, E. (2018). Characterization of clay-rich soils in Eastern Anatolia using XRD analysis. *Journal of Soil Science*, 45(2), 112-125.
- Beare, M. H., Tian, M., Vikram, S., & Srivastava, S. C. (1997). Agricultural intensification, soil biodiversity, and agro-ecosystem function. *Applied Soil Ecology*, 6, 87–108.
- 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, 21–33.
- Bilgili, A. V. (2022). Soil moisture-plant water relationships in clay-rich soils under semi-arid conditions. *Agricultural Water Management*, 259, 107262. <https://doi.org/10.1016/j.agwat.2021.107262>
- Bilgili, A. V., Bayramin, İ., & Dengiz, O. (2020). Remote sensing-based estimation of soil erosion risk using RUSLE model: A case study from Central Anatolia. *Land Degradation & Development*, 31(12), 1508-1521. <https://doi.org/10.1002/ldr.3548>
- Bilgili, A. V., Şahin, M., & Kurucu, Y. (2021). Soil organic carbon dynamics in semi-arid ecosystems: A 10-year monitoring study. *Agriculture, Ecosystems & Environment*, 304, 107175. <https://doi.org/10.1016/j.agee.2020.107175>
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Black, C. A. (1965). Methods of soil analysis: Part I physical and mineralogical properties. American Society of Agronomy, Madison, Wisconsin, USA.
- Blake, G. R., & Hartge, K. H. (1986). Methods of soil analysis. Bulk density, Part 1

- (2nd ed.). ASA and SSSA, Madison.
- Borhani, T. N. G., Saniedanesh, M., Bagheri, M., & Lim, J. S. (2016). QSPR prediction of the hydroxyl radical rate constant of water contaminants. *Water Research*, 98, 344–353.
- Boruvka, L., & Penizek, V. (2007). A test of an artificial neural network allocation procedure using the Czech soil survey of agricultural land data. In P. Lagacherie, A. B. McBratney, & M. Voltz (Eds.), *Digital Soil Mapping: An Introductory Perspective* (pp. 415–424). Elsevier.
- Bouyoucos, G. J. (1955). A recalibration of the hydrometer method for making mechanical analysis of the soils. *Agronomy Journal*, 4(9), 434.
- Brady, N. C., & Weil, R. R. (2010). *Elements of the Nature and Properties of Soils* (3rd ed.). Pearson Education.
- Brady, N. C., & Weil, R. R. (2016). *The nature and properties of soils* (15th ed.). Pearson Education.
- Brady, N. C., & Weil, R. R. (2008). *The nature and properties of soils* (14th ed.). Pearson Prentice Hall.
- Brevik, E. C., & Sauer, T. J. (2015). The past, present, and future of soils and human health studies. *Soil*, 1(1), 35–46.
- Budak, M., Günal, H., Çelik, İ., Yıldız, H., Acir, N., & Acar, M. (2018). Soil quality assessment of upper Tigris basin. *Carpathian Journal of Earth and Environmental Sciences*, 13, 301–316. <https://doi.org/10.26471/cjees/2018/013/026>
- Bünemann, E. K., Bongiorno, G., Bai, Z., Creamer, R. E., De Deyn, G., de Goede, R., ... & Brussaard, L. (2018). Soil quality - A critical review. *Soil Biology and Biochemistry*, *120*, 105-125. <https://doi.org/10.1016/j.soilbio.2018.01.030>
- Byrne, J. M., & Yang, M. (2016). Spatial variability of soil magnetic susceptibility, organic carbon and total nitrogen from farmland in northern China. *Catena*, 145, 92–98.
- Cameron, K., Beare, M. H., McLaren, R. P., & Di, H. (1998). Selecting physical, chemical, and biological indicators of soil quality for degraded or polluted soils. *Proceedings of the 16th World Congress of Soil Science*, Symposium No. 37, Scientific registration No. 2516, Montpellier, France, August 20–26.
- Chen, J., Wei, F., Zheng, C., Wu, Y., & Adriano, D. C. (1996). *Background concentrations of elements in soils of China*. *Water, Air, and Soil Pollution*, 57(1), 699-712.
- Chen, Z. S. (1998). Management of contaminated soil remediation programmes. *Land Contamination & Reclamation*, 6, 41–56.
- Chen, Z. S., Lee, D. Y., Lin, C. F., Lo, S. L., & Wang, Y. P. (1996). Contamination of rural and urban soils in Taiwan. In R. Naidu, R. S. Kookuna, D. P. Oliver,

- S. Rogers, & M. J. McLaughlin (Eds.), *Contaminants and the Soil Environment in the Australasia-Pacific Region* (First Australasia-Pacific Conference on Contaminants and Soil).
- Cherubín, M. R., Tormena, C. A., & Karlen, D. L. (2017). Soil quality evaluation using the Soil Management Assessment Framework (SMAF) in Brazilian Oxisols with contrasting texture. *Revista Brasileira de Ciência do Solo*, 41, e0160148.
- Cömert, Z., & Kocamaz, A. F. (2017). Gelişmiş optimizasyon algoritmalarıyla eğitilmiş yapay sinir ağı modelleri ile sınıflandırma. *Journal of Engineering Sciences and Design*, 5(4), 995–1005.
- Cressie, N. (1993). *Statistics for Spatial Data*. Wiley.
- Çağlar, K. (1949). *Toprak ilmi*. Ankara Üniversitesi Ziraat Fakültesi Yayınları.
- Çavuşlu, M. A., Gürüler, H., & Altın, T. (2012). Levenberg–Marquardt öğrenme algoritması ile yapay sinir ağı kullanarak ekonomik büyüme tahmini. *Akademik Bilişim Konferansı Bildirileri*, Uşak.
- De Andrade Bonetti, J., Nunes, M. R., Fink, J. R., Tretto, T., & Tormena, C. A. (2023). Agricultural practices to improve near-surface soil health and crop yield in subtropical soils. *Soil and Tillage Research*, 234, 105835.
- Delon, C., Serca, D., Boissard, C., Dupont, R., Dutot, A., Laville, P., Rosnay, P. D. R., & Delmas, P. D. (2007). Soil NO emissions modelling using artificial neural network. *Tellus*, 59, 502–513.
- Demir, S., Başkan, O., & Dengiz, O. (2020). Soil erosion risk assessment using GIS and ICONA model: A case study in semiarid Central Anatolia, Turkey. *Environmental Earth Sciences*, *79*(7), 1-15. <https://doi.org/10.1007/s12665-020-8884-x>
- Demirkıran, A. R. (2021). Soil biological activity under organic and conventional farming systems in semi-arid ecosystems. *Applied Soil Ecology*, 158, 103782. <https://doi.org/10.1016/j.apsoil.2020.103782>
- Demirkıran, A. R., & Öztürk, H. S. (2020). Comparative effectiveness of different soil amendments for pH regulation in acidic soils. *Soil Use and Management*, 36(3), 423-435. <https://doi.org/10.1111/sum.12578>
- Demirkıran, A. R., Kılıç, M., & Yalçın, H. (2019). Long-term effects of agricultural practices on soil nutrient cycling in semi-arid regions. *Journal of Plant Nutrition and Soil Science*, 182(4), 589-601. <https://doi.org/10.1002/jpln.201800512>
- Deutsch, C. V., & Journel, A. G. (1998). *GSLIB: Geostatistical Software Library and User's Guide*. Oxford University Press.
- Devlet Su İşleri [DSİ]. (2020). *Solhan Ovası toprak etüt raporu* (Rapor No: 2020/45). Ankara: DSİ Yayınları.
- Diggle, P. J., & Ribeiro, P. J. (2007). *Model-based Geostatistics*. Springer.

- Dinan, H., Mehuys, G. R., & Levesque, M. (1991). Influence of humic and fibric materials on the aggregation and aggregate stability of a lacustrine silty clay. *Soil Science*, 151(2), 146–158.
- Dirik, K., Yürür, T., & Demirbağ, H. (2003). 1 May 2003 Çimenli (Bingöl) Earthquake Assessment Report. Hacettepe University, Faculty of Engineering, Department of Geological Engineering, Ankara.
- Doran, J. W. (2002). Soil health and global sustainability: Translating science into practice. *Agriculture, Ecosystems & Environment*, 88, 119–127.
- Doran, J. W., & Parkin, T. B. (1994). Defining and assessing soil quality. In J. W. Doran, D. C. Coleman, D. F. Bezdicek, & B. A. Stewart (Eds.), *Defining Soil Quality for a Sustainable Environment* (Special Publication No. 35, pp. 3–21). American Society of Agronomy, Madison, WI. <https://doi.org/10.2136/sssaspecpub35.c1>
- EIA. (2016). *Bingöl Province 2016 Environmental Status Report*. Bingöl EIA and Environmental Services Branch Directorate, Bingöl.
- Elshorbagy, A., & Parasuraman, K. (2008). On the relevance of using artificial neural networks for estimating soil moisture content. *Journal of Hydrology*, 362, 1–18.
- Erşahin, S., & Karaman, M. R. (2016). Comparative performance of kriging methods for mapping soil salinity in the Çumra Plain, Central Anatolia, Turkey. *Journal of Agricultural Sciences*, *22*(1), 1-13. https://doi.org/10.1501/Tarimbil_00000001368
- Evliya, H. (1964). *Toprak bilgisi*. Ankara Üniversitesi Ziraat Fakültesi Yayınları.
- FAO. (2006). *Guidelines for Soil Description* (4th ed.). Food and Agriculture Organization of the United Nations.
- FAO. (2021). *The State of the World's Land and Water Resources for Food and Agriculture (SOLAW)*. Food and Agriculture Organization of the United Nations.
- FAO (2020). *Management of Acid Soils for Sustainable Agriculture*.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Upper Saddle River, NJ: Prentice Hall.
- Field, A. (2018). *Discovering statistics using IBM SPSS statistics* (5th ed.). Sage.
- Foresee, F. D., & Hagan, M. T. (1997). Gauss-Newton approximation to Bayesian regularization. *Proceedings of the International Joint Conference on Neural Networks*, 1930–1935.
- Gee, G. W., & Bauder, J. W. (1986). Particle size analysis. In A. Klute (Ed.), *Methods of Soil Analysis* (2nd ed., Agronomy Monograph No. 9). ASA and SSSA.
- Goovaerts, P. (1997). *Geostatistics for natural resources evaluation*. Oxford University Press.

- Govaerts, B., Sayre, K. D., & Deckers, J. (2006). A minimum data set for soil quality assessment of wheat and maize in the highlands of Mexico. *Soil and Tillage Research*, 87, 163–174.
- Gugino, B. K., Abawi, G. S., Idowu, O. J., Schindelbeck, R. R., Smith, L. L., Thies, J. E., Wolfe, D. W., & Van Es, H. M. (2009). *Cornell soil health assessment training manual*. Cornell University College of Agriculture and Life Sciences.
- Gülınar, M., & Barik, K. (2019). Determination of quality parameters of podzolic soils under different land uses. *Atatürk University Journal of Faculty of Agriculture*, 50(2), 128–135.
- Günel, H., Korucu, T., Birkas, M., Özgöz, E., & Halbac-Cotoara-Zamfir, R. (2018). Threats to sustainability of soil functions in Central and Southeast Europe. *Sustainability*, 10(2), 1-17. <https://doi.org/10.3390/su10020279>
- Gyawali, A. J., Neely, H. L., Foster, J. L., Neely, C. B., Lewis, K. L., Bodine, G., & Smith, A. P. (2023). Assessing soil health in a thermic region of the southern Great Plains, using the Soil Management Assessment Framework (SMAF). *Soil Security*, 13, 100115.
- Hagan, M. T., Demuth, H. B., & Beale, M. H. (1996). *Neural Network Design*. Boston, MA: PWS Publishing.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation* (2nd ed.). Upper Saddle River, NJ: Prentice Hall.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson.
- Hengl, T. (2009). *A Practical Guide to Geostatistical Mapping*. Office for Official Publications of the European Communities.
- Hengl, T., Mendes de Jesus, J., Heuvelink, G. B., Ruiperez Gonzalez, M., Kilibarda, M., Blagotić, A., ... & Kempen, B. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLOS ONE*, 12(2), e0169748. <https://doi.org/10.1371/journal.pone.0169748>.
- Hillel, D. (2004). *Introduction to Environmental Soil Physics*. Academic Press.
- Horneck, D. A., & Hanson, D. (1998). *Soil Test Interpretation Guide*. Oregon State University Extension Service.
- Höfle, B., & Rutzinger, M. (2011). Topographic airborne LiDAR in geomorphology: A technological perspective. *Zeitschrift für Geomorphologie*, 55(2), 1-29. <https://doi.org/10.1127/0372-8854/2011/0055S2-0043>
- Hseu, Z. Y., Chen, Z. S., & Tsai, C. C. (1999). Selected indicators and conceptual framework for assessment methods of soil quality in arable soils of Taiwan. *Soil and Environment*, 2, 77–88. (In Chinese, with English abstract and tables).
- ICRCL. (1987). *Guidance on the assessment and redevelopment of contaminated*

- land (Paper 59/83). ICRCCL Department of the Environment, London, UK.
- Isaaks, E. H., & Srivastava, R. M. (1989). *Applied Geostatistics*. Oxford University Press.
- IUSS Working Group WRB. (2022). *World Reference Base for Soil Resources 2022*. International Union of Soil Sciences.
- Ivanov, A. V., Petrov, S. N., & Sidorova, M. A. (2022). Application of artificial neural networks in soil science: A case study of soil organic matter prediction. *Russian Journal of Soil Science*, 54(3), 245–256.
- Ivanov, P. (2018). Soil formation processes in continental climates: A case study from Russia. *Journal of Soil Science and Ecology*, 45(3), 234–245.
- Jackson, M. L. (1960). *Soil chemical analysis*. Prentice Hall Inc.
- Jackson, M.L. (1973). *Soil chemical analysis*. Prentice Hall.
- Jacobs, L. W. (1990). Potential hazards when using organic materials as fertilizers for crop production. *FFTC Extension Bulletin No. 313*. Food and Fertilizer Technology Center of Asia and Pacific Regions (FFTC/ASPAC).
- Jafarnejadi, A., Abbssayyad, G., Arshad, R. R., & Davami, A. (2012). Pedotransfer functions development for field capacity and permanent wilting points using artificial neural networks and regression models. *International Journal of Agriculture*, *2*, 1079-1084.
- Jimenez, L. C. Z., Queiroz, H. M., Cherubín, M. R., & Ferreira, T. O. (2022). Applying the Soil Management Assessment Framework (SMAF) to assess mangrove soil quality. *Sustainability*, 14(5), 3085.
- Journel, A. G., & Huijbregts, C. J. (1978). *Mining Geostatistics*. Academic Press.
- Kacar, B., & Katkat, A. V. (2010). *Bitki Besleme*. Nobel Yayın Dağıtım.
- Karaca, A. (2020). *Soil formation and soil types in Turkey*. Ankara University Publications.
- Karlen, D. L., Andrews, S. S., & Doran, J. W. (2001). Soil quality: Current concepts and applications. *Advances in Agronomy*, 74, 1–40.
- Karlen, D. L., Cambardella, C. A., Kovar, J. L., & Colvin, T. S. (2013). Soil quality response to long-term tillage and crop rotation practices. *Soil and Tillage Research*, 133, 54–64.
- Karlen, D. L., Mausbach, M. J., Doran, J. W., Cline, R. G., Harris, R. F., & Schuman, G. E. (1997). Soil quality: A concept, definition, and framework for evaluation. *Soil Science Society of America Journal*, 61(1), 4-10. <https://doi.org/10.2136/sssaj1997.03615995006100010001x>
- Karlen, D. L., Tomer, M. D., Neppel, J., & Cambardella, C. A. (2008). A preliminary watershed scale soil quality assessment in north central Iowa, USA. *Soil and Tillage Research*, 99(2), 291–299.
- Karlen, D. L., Veum, K. S., Sudduth, K. A., Obrycki, J. F., & Nunes, M. R. (2019).

- Soil health assessment: Past accomplishments, current activities, and future opportunities. *Soil and Tillage Research*, 195, 104365.
- Kerry, R., & Oliver, M. A. (2007). Determining the effect of asymmetric data on the variogram. I. Underlying asymmetry. *Computers & Geosciences*, 33(10), 1212-1232. <https://doi.org/10.1016/j.cageo.2007.05.008>.
- Keshavarzi, A., Sarmadian, F., Labbafi, R., & Ahmadi, A. (2011). Developing pedotransfer functions for estimating field capacity and permanent wilting point using fuzzy table look-up scheme. *Computer and Information Science*, 4(1), 130-138.
- Keskin, H., Grunwald, S., & Harris, W. G. (2019). Digital mapping of soil carbon fractions with machine learning in Bursa, Turkey. *Geoderma Regional*, 16, e00208. <https://doi.org/10.1016/j.geodrs.2019.e00208>
- Kılıç, M., & Şenol, H. (2023). Integrated geostatistical mapping of soil salinity using topographic wetness index and remote sensing data. *Geoderma*, 430, 116352. <https://doi.org/10.1016/j.geoderma.2022.116352>
- Kılıç, M., Bayram, E., & Öztürk, H. S. (2022). Adaptive soil quality indexing for semi-arid ecosystems using hybrid artificial neural networks. *Science of The Total Environment*, 806, 150642. <https://doi.org/10.1016/j.scitotenv.2021.150642>
- Kılıç, M., Demir, Y., & Yılmaz, K. (2021). Comparative analysis of machine learning algorithms for soil organic carbon prediction in semi-arid regions. *Computers and Electronics in Agriculture*, 182, 106003. <https://doi.org/10.1016/j.compag.2021.106003>
- Kirda, C., & Sarıyev, A. (2002). *Toprak Fiziği*. Çukurova Üniversitesi Ziraat Fakültesi Genel Yayın No: 245, Ders Kitapları Yayın No: A-79, Adana.
- Klute, A. (1986). Water retention: Laboratory methods. In *Methods of Soil Analysis, Part 1* (2nd ed., Agronomy Monograph No. 9). ASA and SSSA.
- Kovda, I., Morgun, E., & Lebedeva, M. (2019). Vertisols in continental climates: Properties and management. *Eurasian Soil Science*, 52(5), 567–576.
- Kuplich, T. M. (2009). Classifying regenerating forest stages in Amazônia using remotely sensed images and a neural network. *Forest Ecology and Management*, 234, 1–9.
- Lakzian, A., Aval, M. B., & Gorbanzadeh, N. (2010). Comparison of pattern recognition, artificial neural network and pedotransfer functions for estimation of soil water parameters. *Notulae Scientia Biologicae*, 2(3), 114-120.
- Lal, R. (2020). Soil organic matter and water retention. *Agronomy Journal*, 112(5), 3265-3277. <https://doi.org/10.1002/agj2.20282>
- Lamorski, K., Pachepsky, Y., Sławiński, C., & Walczak, R. T. (2014). Using support vector machines to develop pedotransfer functions for water retention of soils

- in Poland. *Soil Science Society of America Journal*, *78*(4), 1453-1463. <https://doi.org/10.2136/sssaj2013.09.0405>
- Larson, W. E., & Pierce, F. J. (1991). Conservation and enhancement of soil quality. In *Evaluation for Sustainable Land Management in the Developing World* (pp. 34–61). IBSRAM Proc., Vol. 2: Technical Papers. Bangkok, Thailand.
- Lentzsch, P., Wieland, R., & Wirth, S. (2005). Application of multiple regression and neural network approaches for landscape-scale assessment of soil microbial biomass. *Soil Biology and Biochemistry*, 37, 1577–1580.
- Li, J., & Heap, A. D. (2011). A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. *Ecological Informatics*, 6(3-4), 228-241.
- Li, X., et al. (2024). Hybrid AI models for precision soil quality indexing. *Agriculture, Ecosystems & Environment*, 349, 108452. <https://doi.org/10.1016/j.agee.2023.108452>
- Loeppert, R.H., & Suarez, D.L. (1996). Carbonate and gypsum. In *Methods of soil analysis, Part 3* (pp. 437-474). SSSA.
- Machado, R. M. A., & Serralheiro, R. P. (2017). Soil salinity: Effect on vegetable crop growth and management practices to mitigate its impacts. *Horticulturae*, 3(2), 30.
- MacKay, D. J. C. (1992). A Practical Bayesian Framework for Backpropagation Networks. *Neural Computation*, 4(3), 448–472.
- Malgwi, W. B., & Abu, S. T. (2011). Variation in some physical properties of soils formed on a hilly terrain under different land use types in Nigerian savanna. *International Journal of Soil Science*, 6(3), 150–163.
- Manyame, C., Morgan, C. L., Heilman, J. L., Fatondji, D., Gerard, B., & Payne, W. A. (2007). Modeling hydraulic properties of sandy soils of Niger using pedotransfer functions. *Geoderma*, 141, 407–415.
- Marquardt, D. W. (1963). An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *SIAM Journal on Applied Mathematics*, 11(2), 431–441.
- McBratney, A. B., Santos, M. M., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117, 3–52.
- Meteoroloji Genel Müdürlüğü [MGM]. (2021). *Solhan ilçesi 1990-2020 iklim verileri*. Ankara: MGM Yayınları.
- Minasny, B., & Hartemink, A. E. (2011). Predicting soil properties in the tropics. *Earth-Science Reviews*, 106, 52–62.
- Ministry of Housing - Netherlands. (1994). *Dutch intervention values of heavy metals and organic pollutants in soils, sediments, and groundwater*. Physical Planning and Environmental Conservation Report HSE 94.021.
- Mirsal, I. A. (2008). *Soil pollution: Origin, monitoring & remediation* (2nd ed.). Springer.

- Mohanty, M., Nishant, K., Sinha, D. K., Painuli, K. K., Bandyopadhyay, K. M., Hati, K., Sammi Reddy, & Chaudhary, R. S. (2015). Modelling soil water contents at field capacity and permanent wilting point using artificial neural network for Indian soils. *National Academy Science Letters*, *38*(5), 373-377.
- Moller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4), 525-533.
- Moncada Penning, L. H., Timm, L. C., Gabriels, D., & Cornelis, W. M. (2017). Visual examination of changes in soil structural quality due to land use. *Soil and Tillage Research*, 173, 83–91.
- Mukherjee, A., & Lal, R. (2014). Comparison of soil quality index using three methods. *PLoS One*, 9(8), e105981.
- Neal, R. M. (1996). *Bayesian Learning for Neural Networks*. New York: Springer.
- Nelson, D. W., & Sommers, L. E. (1982). Organic matter. In A. Klute (Ed.), *Methods of Soil Analysis* (2nd ed., Agronomy Monograph No. 9, pp. 574–579). ASA and SSSA.
- Nelson, D. W., & Sommers, L. E. (1996). Total carbon, organic carbon, and organic matter. In D. L. Sparks (Ed.), *Methods of soil analysis: Part 3—Chemical methods* (pp. 961-1010). Soil Science Society of America.
- Nocedal, J., & Wright, S. J. (2006). Numerical optimization. Springer Science & Business Media.
- Nunes, M. R., Karlen, D. L., Veum, K. S., & Moorman, T. B. (2020). A SMAF assessment of US tillage and crop management strategies. *Environmental and Sustainability Indicators*, 8, 100072.
- Özbek, H. (1979). *Toprak Bilgisi*. Ankara Üniversitesi Ziraat Fakültesi Yayınları, No: 709.
- Özcan, H., & Erşahin, S. (2001). Farklı toprak özelliklerine sahip alanlarda solma noktası ve tarla kapasitesinin belirlenmesi. *Tarım Bilimleri Dergisi*, 7(4), 67-73.
- Öztaş, T. (2002). Assessment of soil quality. In *International Conference on Sustainable Land Use and Management* (pp. 484–485). Çanakkale.
- Öztaş, T. (1997). Soil degradation. *Ecology*, 22, 31–33.
- Öztürk, H. S., Çaycı, G., & Baran, A. (2015). Long-term changes in soil quality indicators in arable soils of Central Anatolia. *Turkish Journal of Agriculture and Forestry*, *39*(3), 430-440. <https://doi.org/10.3906/tar-1406-172>
- Öztürk, M., Celik, I., & Gunes, A. (2020). Characteristics and agricultural potential of volcanic origin soils in Turkey. *Anatolian Journal of Agricultural Sciences*, 35(1), 45–58.
- Öztürk, M., Salman, O., & Koc, M. (2011). Artificial neural network model for estimating the soil temperature. *Canadian Journal of Soil Science*, 91, 551–562.

- Pacci, S., & Dengiz, O. (2023). Ayçiçeği tarımı yapılan toprakların SMAF modeli ile toprak kalite indislerinin belirlenmesi: Tokat Zile İlçesi örneği. *Toprak Bilimi ve Bitki Besleme Dergisi*, 11(1), 54–66.
- Pacci, S., Dengiz, O., Saygin, F., & Alaboz, P. (2022). Soil quality assessment of paddy cultivation lands in the Bafra plain based on the SMAF model. *Turkish Journal of Agricultural Research*, 9(2), 164–174. <https://doi.org/10.19159/tutad.1067105>
- Pahlavan-Rad, M. R., & Akbarimoghaddam, A. (2018). Spatial variability of soil texture fractions and pH in a flood plain (case study from eastern Iran). *Catena*, 160, 275–281.
- Paswan, R. P., & Begum, S. H. A. (2013). Regression and neural networks models for prediction of crop production. *International Journal of Scientific & Engineering Research*, 4, 98–108.
- Pebesma, E. J. (2004). Multivariable geostatistics in S: the gstat package. *Computers & Geosciences*, 30(7), 683–691.
- Pochvovedenie. (2020). *Fundamentals of soil science and its applications in modern agriculture*. Nauka Press.
- Raiesi, F. (2017). A minimum data set and soil quality index to quantify the effect of land use conversion on soil quality and degradation in native rangelands of upland arid and semiarid regions. *Ecological Indicators*, 75, 307–320.
- Ranjbar, F., & Jalali, M. (2016). The combination of geostatistics and geochemical simulation for the site-specific management of soil salinity and sodicity. *Computers and Electronics in Agriculture*, 121, 301–312.
- Renard, K. G., Foster, G. R., Weesies, G. A., McCool, D. K., & Yoder, D. C. (1997). *Predicting soil erosion by water: A guide to conservation planning with the Revised Universal Soil Loss Equation (RUSLE)* (Agriculture Handbook No. 703). U.S. Department of Agriculture.
- Rengel, Z. (2015). *Availability of Mn, Zn and Fe in the rhizosphere*. *Journal of Soil Science and Plant Nutrition*, 15(2), 397–409.
- Rengel, Z. (2015). Soil pH, soil health and climate change. In *Soil Biology* (Vol. 49). Springer.
- Rezaei, S. A., Gilkes, R. J., & Andrews, S. S. (2006). A minimum data set for assessing soil quality in rangelands. *Geoderma*, 136(1–2), 229–234.
- Rhoades, J. D., Chandavi, D., & Lesch, S. F. (1999). Soil salinity assessment methods and interpretation of electrical conductivity measurement. FAO Irrigation and Drainage Paper 57, Rome.
- Rhoades, J. D., Kandiah, A., & Mashali, A. M. (1999b). *The use of saline waters for crop production* (FAO Irrigation and Drainage Paper No. 48). FAO.
- Rowell, D. L. (1994). *Soil Science: Methods and Applications*. Longman Group UK Limited.

- Rumelhart, D. E., & McClelland, J. L. (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Volume 1: Foundations*. Cambridge, MA: MIT Press.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Saffari, M., Yasrebi, J., Sarikhani, F., Gazni, R., Moazallahi, M., Fathi, H., & Emadi, M. (2009). Evaluation of artificial neural network models for prediction of spatial variability of some soil chemical properties. *Research Journal of Biological Sciences*, 4(7), 815-820.
- Sağlam, M. (2013). Grouping of soil properties with multivariate statistical methods. *Journal of Soil and Water*, 2(1), 7-14.
- Sarivev, A., Sesveren, S., Tülün, Y., Kaman, H., & Acar, M. (2020). Determination of unsaturated hydraulic conductivity at field conditions and mathematical modeling.
- Schachtschabel, P., Blume, H. P., Brümmer, G. B., Hartge, K. H., & Schwertmann, U. (2007). *Soil science* (Çeviren: H. Özbek, M. Gök, & H. Kaptan). Çukurova Üniversitesi Ziraat Fakültesi Genel Yayın No: 73, Adana.
- Schoeneberger, P. J., Wysocki, D. A., Benham, E. C., & Broderick, W. D. (2012). *Field book for describing and sampling soils* (Version 3.0). Natural Resources Conservation Service.
- Seyedmohammadi, J., Esmaelnejad, L., & Ramezanpour, H. (2016). Determination of a suitable model for prediction of soil cation exchange capacity. *Modeling Earth Systems and Environment*, 2(3), 156. <https://doi.org/10.1007/s40808-016-0230-2>
- Sezer, K. (2012). *Toprak Verimliliği ve Gübreleme*. Ankara Üniversitesi Yayınları.
- Shahid, S. A., Zaman, M., & Heng, L. (2018). Soil salinity: Historical perspectives and a world overview of the problem. In *Guideline for salinity assessment, mitigation and adaptation using nuclear and related techniques* (pp. xx-xx). Springer.
- Shewchuk, J. R. (1994). An introduction to the conjugate gradient method without the agonizing pain. *Technical Report CMU-CS-94-125*, Carnegie Mellon University.
- Shishov, L. L., Komarova, T. A., & Goryachkin, S. V. (2021). Modern approaches to soil classification using machine learning techniques. *Eurasian Soil Science*, 53(7), 987-998.
- Shukla, M. K., Lal, R., & Ebinger, M. (2006). Determining soil quality indicators by factor analysis. *Soil and Tillage Research*, 87, 194-204.
- Six, J., Bossuyt, H., Degryze, S., & Denef, K. (2004). A history of research on the link between (micro)aggregates, soil biota, and soil organic matter dynamics. *Soil and Tillage Research*, 79(1),

- Soil Survey Staff. (2014). *Keys to soil taxonomy* (12th ed.). USDA-NRCS.
- Solhan Tarım ve Orman İlçe Müdürlüğü [STİM]. (2022). *Solhan Ovası tarımsal üretim istatistikleri ve arazi kullanım raporu*. Bingöl: STİM Yayınları.
- Sparks, D. L. (2003). *Environmental soil chemistry* (2nd ed.). Academic Press.
- Sposito, G. (2016). *The chemistry of soils* (3rd ed.). Oxford University Press.
- Stevenson, F. J. (2005). Nitrogen-organic forms. In *Methods of Soil Analysis, Part 3: Chemical Methods* (4th ed.). Soil Science Society of America, Madison, WI, USA.
- Summer, M. E., & Miller, W. P. (1996). Cation exchange capacity and exchange coefficient. In D. L. Sparks (Ed.), *Methods of Soil Analysis* (SSSA Book Series 5, pp. 1205–1230). Soil Science Society of America.
- Şeker, C., Ozaytekin, H. H., Negiş, H., Gümüş, İ., Dedeoğlu, M., Atmaca, E., & Karaca, U. (2017). Assessment of soil quality index for wheat and sugar beet cropping systems on an entisol in Central Anatolia. *Environmental Monitoring and Assessment*, 189(4), 135.
- Şenol, H., Alaboz, P., Demir, S., & Dengiz, O. (2020). Computational intelligence applied to soil quality index using GIS and geostatistical approaches in semiarid ecosystem. *Arabian Journal of Geosciences*, 13(23), Article 1-20.
- Şenol, H., Öztürk, A., Akça, E., & Kılıç, Ö. M. (2021). Comparison of machine learning algorithms for mapping soil salinity using Sentinel-2 and Landsat-8 OLI data in semi-arid regions. *Geocarto International*, *36*(16), 1855-1873. <https://doi.org/10.1080/10106049.2021.1973119>
- Şensoy, S., Kara, A., & Akça, E. (2013). Toprakların su tutma özelliklerinin belirlenmesinde kullanılan yöntemlerin karşılaştırılması. *Toprak Bilimi Dergisi*, 2(1), 15-22.
- Tabachnick, B. G., & Fidell, L. S. (2019). *Using multivariate statistics* (7th ed.). Pearson.
- Tavşancıl, E. (2005). *Measuring attitudes and data analysis with SPSS*. Nobel Publishing.
- Thomas, G.W. (1982). Exchangeable cations. In *Methods of soil analysis, Part 2* (pp. 159-165). ASA-SSSA.
- Tiller, K. G. (1992). Urban soil contamination in Australia. *Australian Journal of Soil Research*, 30, 937–957.
- Toth, G., Stolbovoy, V., & Montanarella, L. (2007). *Soil quality and sustainability evaluation: An integrated approach to support soil-related policies of the European Union* (JRC Position Paper, EUR 22721 EN). European Commission. <https://doi.org/10.2788/36701>
- Tripathi, R., Nayak, A. K., Shahid, M., Lal, B., Gautam, P., Raja, R., Mohanty, S.,

- Kumar, A., Panda, B. B., & Sahoo, R. N. (2015). Delineation of soil management zones for a rice cultivated area in eastern India using fuzzy clustering. *Catena*, 133, 128-136. <https://doi.org/10.1016/j.catena.2015.05.009>
- Turhan, E., & Erpul, G. (2009). The application of artificial neural networks for soil classification in semi-arid regions. *Environmental Monitoring and Assessment*, 156, 413–421
- Tümsavaş, Z., Bayramin, İ., & Yılmaz, K. (2019). Hydraulic conductivity estimation of clay-rich soils in semi-arid regions. *Turkish Journal of Agriculture and Forestry*, 43(3), 245-256. <https://doi.org/10.3906/tar-1806-142>
- Türk, M., & Gülsoy, A. (2003). Soils of Turkey: Formation and classification. *Turkish Journal of Agriculture and Forestry*, 27, 123–133.
- Türker, U., Çalışkan, M. E., & Kara, M. (2012). Sulama planlamasında toprak neminin izlenmesi. *Toprak Su Dergisi*, 1(1), 11–21.
- Türkiye İstatistik Kurumu (TÜİK). (2021). *Türkiye Toprak Verileri*. <https://www.tuik.gov.tr>
- Tüzüner, A. (1990). *Toprak ve su analiz laboratuvarları el kitabı*. Tarım Orman ve Köyışleri Bakanlığı, Köy Hizmetleri Genel Müdürlüğü Yayınları No: 62.
- U.S. Salinity Laboratory Staff. (1954). *Diagnosis and improvement of saline and alkali soils* (USDA Agriculture Handbook No. 60). USDA.
- United States Department of Agriculture. (2023). *Soil texture classification*. Natural Resources Conservation Service. <https://www.nrcs.usda.gov/resources/guides-and-instructions/soil-texture-classification>.
- United States Environmental Protection Agency (USEPA). (1989). Standards for the disposal of sewage sludge: Proposed rules. *Federal Register*, 54, 5778–5902
- USDA-NRCS (2019). *Soil pH and Organic Matter: Nutrient Management Module*.
- Veum, K. S., Sudduth, K. A., Kremer, R. J., & Kitchen, N. R. (2017). Sensor data fusion for soil health assessment. *Geoderma*, 305, 53–61. <https://doi.org/10.1016/j.geoderma.2017.05.031>
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The Standardized Precipitation Evapotranspiration Index. *Journal of Climate*, 23(7), 1696-1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Viscarra Rossel, R. A., Walvoort, D. J. J., McBratney, A. B., Janik, L. J., & Skjemstad, J. O. (2006). Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, 131(1–2), 59–75.
- Wander, M. M., & Bollero, G. A. (2000). Soil quality assessment: Past, present and future. *Soil Science Society of America Journal*, 64, 61–68.
- Wang, Y., et al. (2022). Predicting soil organic carbon using deep

- learning. *Geoderma*, 405, 115400. <https://doi.org/10.1016/j.geoderma.2021.115400>
- Wani, J. A., Wani, S. A., Bhat, M. A., & Lal, R. (2017). Spatial variability of soil micronutrients in karewa soils of Kashmir Himalaya, India. *Environmental Earth Sciences*, 76(7), 1-13. <https://doi.org/10.1007/s12665-017-6592-y>
- Webster, R., & Oliver, M. A. (2007). *Geostatistics for Environmental Scientists*. Wiley. <https://doi.org/10.1002/9780470517277>
- Weiss, A. D. (2001). Topographic position and landforms analysis. *Proceedings of the ESRI User Conference*, San Diego, CA.
- Were, K., Bui, D. T., Dick, Ø. B., & Singh, B. R. (2015). A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. *Ecological Indicators*, 52, 394-403. <https://doi.org/10.1016/j.ecolind.2014.12.028>
- Williams, B. G., & Duncan, J. M. (1998). Predicting soil moisture with neural networks. *Soil Science Society of America Journal*, 62, 1102–1108.
- Wilson, B. R., Brown, L., & Smith, J. (2016). Mapping phosphorus levels in agricultural soils using geospatial analysis. *Agricultural Systems*, 147, 45–54.
- Yang, Z., & Shami, A. (2020). *On hyperparameter optimization of machine learning algorithms: Theory and practice*. *Neurocomputing*, 415, 295–316. <https://doi.org/10.1016/j.neucom.2020.07.061>
- Yeganeh, S., & Ahangar, A. A. (2011). Artificial neural networks and regression models in prediction of crop yield: A comparative study. *Agricultural Engineering International: CIGR Journal*, 13(2), 9–19.
- Yong, R. N., & Warkentin, B. P. (1975). *Soil properties and behavior*. Elsevier.
- Zhang, L., Wang, Y., Li, J., & Chen, H. (2023). *High-resolution mapping of soil quality indices using deep learning and remote sensing: A global analysis*. *Science of The Total Environment*, 864, 160991. <https://doi.org/10.1016/j.scitotenv.2022.160991>
- Zhang, X., Qian, H., Chen, J., & Qiao, L. (2020). The role of clay minerals in the retention of soil nutrients. *Geoderma*, 361, 114065. <https://doi.org/10.1016/j.geoderma.2019.114065>
- Zhu, A. X. (2000). Mapping soil landscape as spatial continua: The neural network approach. *Water Resources Research*, 36(3), 663–677.