BÖLÜM XV

ŞEFTALİ YETİŞTİRİCİLİĞİ ALANINDA MAKİNE ÖĞRENİMİNE DAYALI GÜNCEL ÇALIŞMA ÖRNEKLERİ

Dr. Öğr. Üyesi Tolga HAYIT[1]

DOI: https://dx.doi.org/10.5281/zenodo.10138584

[1]Yozgat Bozok Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Yozgat, Türkiye, tolga.hayit@bozok.edu.tr, Orcid ID: 0000-0001-5367-7988

GİRİŞ

Şeftali (*Prunus persica*), tarım ve ziraat sektöründe önemli bir yere sahip olan meyvelerden biridir. Şeftali, taze olarak tüketildiği gibi konserveler, reçeller, meyve suyu, dondurma ve diğer gıda ürünlerinin yapımında da kullanılır. Bu nedenle ticari olarak büyük talep gören bir meyve türüdür ve tarım sektörüne önemli gelir kaynakları sağlar (Vural ve Çakan, 2021; Okan ve Engindeniz, 2016). Şeftali yetiştiriciliği, ülkemiz için önemli bir gelir kaynağıdır. 2018 verilerine göre Türkiye, 789 bin ton şeftali üretimi ile dünyanın en büyük 5. üreticisi ve 110 bin tonu aşan kapasitesi ile de dünyanın en büyük 4. ihracatçısı konumundadır (Vural ve Çakan, 2021). Bu nedenle şeftali, yüksek verimliliği ve talep edilen lezzeti sayesinde çiftçilere karlı bir tarım ürünü sunar. İklim ve toprak koşullarına uygun olduğu bölgelerde yetiştirilerek dış ticaret açısından önemli bir rol oynar.

Giderek artan dünya nüfusu, iklim değişikliği, doğal kaynakların azalması ve ekonomik dengesizlikler, meyve, sebze vb. gıdalara olan talepleri artırmaktadır. Evrensel olarak bu taleplerin karşılanması her geçen gün daha da zorlaşmaktadır. Talepleri karşılama ihtiyacı tarım sektörüne yönelik teknoloji destekli alternatif çözümlerin geliştirilmesinin ve teşvik edilmesinin önünü açmıştır.

Tarım sektörü için yapay zekâya dayalı uygulamalar, tarımda verimliliği artırmak (Ghadge ve diğerleri, 2018; Elavarasan ve Vincent, 2020; Paudel ve diğerleri, 2021), hastalık ve zararlılarla mücadele etmek (Ayan ve diğerleri, 2020; Hayit ve diğerleri, 2021; Hayit ve diğerleri, 2023), üretim proseslerini optimize etmek (Kumar ve diğerleri, 2011; Diao ve diğerleri, 2015), tarım ürünlerinin pazarlama ve satış stratejilerine yönelik öngörüler sağlamak (Brei, 2020, Kumar ve diğerleri, 2021) gibi amaçlarla yaygın olarak kullanılmaktadır. Bu amaçlarla kullanılan yapay zekâ uygulamaları, tarım sektöründe daha sürdürülebilir, verimli ve çevre dostu bir yaklaşımın benimsenmesine katkı sağlamaktadır. Yapay zekâ ve diğer dijital tarım teknolojileri, çiftçilerin daha bilinçli ve akıllı tarım uygulamaları yapmalarına yardımcı olarak küresel tarımsal zorluklarla mücadelede önemli bir rol oynamaktadır.

Makine öğrenimi (ML: machine learning), büyük veri setlerini analiz ederek desenleri, ilişkileri ve tahminleri belirleyebilen bir yapay zekâ dalıdır

(Zhou, 2021). Ziraat mühendisliği ile bilgisayar, elektrik-elektronik, endüstri vb. mühendislik dallarını bir araya getiren disiplinler arası çalışmalar çiftçinin ve üreticinin taleplerini karşılamaya yönelik çözümler üretilebilmesi bağlamında önem taşımaktadır. İlgili alanda yapılan çalışmaların giderin artması ve teşvik edilmesi, sonraki dönemde yapılacak çalışmalara zemin hazırlar niteliktedir.

Makine öğreniminin ilgili alanda ele alınabilmesi için çerçeveye farklı açılardan bakılması gerekmektedir. ML, içerisinde birçok algoritma ve yaklaşım barındırmaktadır. Her bir yaklaşımın işe yarayabileceği farklı disiplinler ve uygulamalar bulunabilir. Yazı devamında ML'nin ziraat alanında genel olarak ne gibi amaç ve uygulamalar için kullanılabildiği özetlenmiştir.

Verimlilik ve kalite artışı, ziraat alanında üretimin her aşaması için dikkate alınması gereken bir olgudur (Karpatne ve diğerleri, 2016). Bu kapsamda ML, tarım arazilerinin ve bitkilerin izlenmesi için sensörler ve kameralarla entegre edilebilir (Yuh ve diğerleri, 2023). Toprak özelliklerini, bitki büyümesini ve su ihtiyacını analiz ederek daha verimli tarım uygulamaları sağlar. Bu sayede ürün kalitesi artmakta, israf azalmakta ve daha az kaynakla daha fazla ürün elde edilebilmektedir.

Diğer yandan, hastalık ve zararlılarla mücadele konusu küresel ısınma ve iklim değişikliği ile bağlantısı neticesinde yapay zekâ alanında çalışan araştırmacıların dikkatini çeken bir konudur (Wani ve Ashtankar, 2017; Durgabai ve Bhargavi, 2018; Domingues ve diğerleri, 2022). Bitki hastalıklarının ve zararlıların erken teşhisi, etkili bir mücadele stratejisinin belirlenmesi için kritik öneme sahiptir. ML, bitki hastalıklarını ve zararlıları görüntü analizi ile tespit ederek çiftçilere zamanında ve hassas müdahale olanakları sunmaktadır.

Sulama işlemleri ve yönetimi kapsamında ML tabanlı sistemler (Gumiere ve diğerleri, 2020; Abioye ve diğerleri, 2022), tarım arazilerinin toprak nem düzeyini ve bitki su ihtiyacını tahmin ederek sulama yönetimini optimize eder. Bu, su kaynaklarının verimli kullanılmasını sağlar ve su israfını en aza indirir.

Ziraat alanında tahmin ve planlamaya yönelik çalışmalar da gerçekleştirilmiştir (Sujjaviriyasup ve Pitiruek, 2013; Gonzalez-Sanchez ve diğerleri, 2014; Chelliah ve diğerleri, 2022). ML, meteorolojik verileri, toprak koşullarını ve geçmiş üretim verilerini analiz ederek gelecekteki üretim miktarı ve kalitesi hakkında tahminler yapar. Bu bilgiler, çiftçilerin daha iyi planlama yapmalarını ve kaynaklarını daha etkin bir şekilde kullanmalarını sağlayabilmektedir.

Makine öğrenimi, tarım makinelerini ve robotları otomatik hale getirerek tarım işlemlerini insan müdahalesi olmadan gerçekleştirebilmektedir. Otomatik hasat sistemleri, otonom traktörler ve tarım robotları gibi uygulamalar, iş gücü maliyetini azaltır ve tarım süreçlerini daha verimli hale getirir. Otomasyon ve Robotik kapsamında ilgili alanda dikkate değer çalışmalar yapılmaktadır (Bini ve diğerleri, 2020; Saleem ve diğerleri, 2021; Shaikh ve diğerleri, 2022).

Son olarak pazarlama ve tüketici tercihleri bağlamında ML, tüketici eğilimlerini ve pazar taleplerini analiz ederek ürün pazarlamasında kullanılabilir. Bu sayede çiftçiler, talebe göre ürün çeşitliliğini ve miktarını ayarlayabilirler. Bu alanda yer alan çalışmalar (Mohanty ve diğerleri, 2020; Hsu ve diğerleri, 2020; Aravatagimath ve diğerleri, 2021) bu hususları dikkate almaktadır.

Diğer tarım ürünlerinde olduğu gibi şeftali yetiştiriciliği alanında da yapay zekâ, çeşitli amaçlar için başarılı bir şekilde kullanılmaktadır. Bu bölümde, belirtilen çeşitli uygulamalar çerçevesinde şeftali yetiştiriciliği alanına yönelik literatürde yer alan ve dikkat çeken, son beş yıl içerisinde yapılan farklı çalışmalara yer verilmiştir.

Makine öğrenim yöntemleri mahsullerde ve meyvelerde olgunlaşma tahmini üzerine kullanılmaktadır. Şöyle ki, Ljubobratović ve diğerleri (2022) tarafından yapılan çalışmada 180 adet "'Suncrest" şeftali türü verilerini içeren bir veri kümesi üzerinde sekiz makine öğrenimi modeli eğitilmiştir. Eğitimden önce veri kümesi en küçük mutlak daralma ve seçim operatörü kullanılarak boyut azaltma işlemine tabi tutulmuştur. Seçilen modellerin AUC değerleri karşılaştırılmış ve yapay sinir ağı tabanlı (ANN: Artificial Neural Network) model, ortalama AUC değeri 0.782 ile en iyi performansı elde etmiştir. Çalışmada ANN haricinde Lineer Diskriminant Analiz, Lojistik Regresyon,

Gradyan Arttırma, Rastgele Orman (RF: Random Forest), Destek Vektör Makineleri (SVM: Support Vector Machine), Sınıflandırma ve Regresyon Ağaçları Modeli Ve K-en Yakın Komşu (KNN: K-Nearest Neighbor) algoritmaları kullanılmıştır. Modellerin performansı için AUC verisini desteklemek amacıyla doğruluk ve F1-Skor gibi parametreler de kullanılmıştır. Analiz sonuçları ve diğer performans göstergeleri ANN modelini doğrulamıştır. ANN'nin, verilen veri kümesinde şeftali olgunlaşma tahmini için en doğru model olduğunu kanıtlanmıştır. Bir diğer çalışmada Avrupa ve Hırvatistan'da popüler olan şeftali meyvesinin olgunluğunun hasat sırasında meyve kalitesi, depolama ömrü ve tüketici kabulü üzerindeki önemli etkileri incelenmiştir (Ljubobratović ve diğerleri, 2021). Çalışmanın temel amacı, önce modelleri eğitmek ve ardından bu modellerin önem derecelerini kullanarak şeftali olgunluğunu tahmin etmek için en önemli özellikleri tespit eden bir makine öğrenimi modeli geliştirmektir. Çalışmada hasat edilen şeftaliler üzerinde toplam 33 meyve özelliği ölçülmüş ve 1.84, 3.57 ve 4.59 $kg \cdot cm^{-2}$ sertlik eşikleri kullanılarak üç dengesiz veri kümesi oluşturulmuştur. Bu veri kümeleri SMOTE ve ROSE teknikleri kullanılarak dengelenmiş ve RF makine öğrenimi modeli üzerinde eğitilmiştir. Permutation Feature Importance, Variable Importance ve LIME yorumlanabilirlik yöntemleri kullanılarak, verilen ML modellerinde tahminleri en çok etkileyen değişkenler tespit edilmeye çalışılmıştır. Şeftali meyve olgunluğunun tahmin edilmesine yönelik başka bir çalışmada, şeftali olgunluğunu temsil etmek için yaygın olarak kullanılan parametrenin "sertlik" parametresi olduğu bildirilmiştir (Ljubobratović ve diğerleri, 2020). Bu bağlamda ilgili çalışmada, şeftali olgunluğunu belirlemek için şeftali empadansına dayalı bir alternatif yöntem önerilmiştir. İçerisinde şeftali empadansı ile ilişkili verilerin de bulunduğu veri setinin analizinde, düşük açıklanabilirlikle karakterize edilen, yüksek doğruluklu makine öğrenimi modellerinden biri olan "black box" (siyah kutu) modellerinden biri kullanılmıştır. Son dönem çalışmalarından Zhang ve Ye (2022) tarafından yapılan çalışmada, şeftali olgunluğunu hızlı ve zararsız tespit edebilmek için derin öğrenme modellerinden biri olan YOLOv5 tabanlı derin öğrenme modeli önerilmiştir. Çalışmanın mimarisi veri toplama, model eğitimi ve model uygulama süreçlerini kapsamaktadır. Çalışmanın sonuçlarına göre, önerilen yeni algoritmanın diğer karşılaştırma algoritmalarına göre açık avantajlara sahip olduğu bildirilmiştir.

Şeftali bitkisinin besin durumunun teşhis edilmesi için mevcut yöntemlere ek olarak ML destekli iyi belgelenmiş veri setlerine ihtiyaç bulunduğu bildirilmiştir (Leitzke Betemps ve diğerleri, 2020). Bu kapsamda yapılan bir çalışmada, şeftali ağaçlarının besin teşhisini yerel ölçekte özelleştirmek amacıyla ML metotları kullanılmıştır (Leitzke Betemps ve diğerleri, 2020). Çalışma kapsamında araştırmacılar, Brezilya'nın Rio Grande do Sul eyaletindeki ticari meyve bahçeleri ve gübre denemelerinden şeftali meyvesinin on bir çeşidi ve altı anaçtan 472 gözlem toplamışlardır. RF sınıflandırma modeli %80 olan bir doğrulukla çalışmıştır.

Hassas sulama ve yapay tozlaşma yönetimi için sahada takibi zahmetli ve zaman alıcı olan şeftali çiçeklenme fenolojisinin doğru bilinmesi gerekmektedir (Zhu ve diğerleri, 2022). Zhu ve diğerleri (2022) tarafından yapılan çalışmada, şeftali çiçeklenme fenolojik aşamalarını tanımlamak için ML tabanlı modeller kullanılmıştır. Çalışmada üç farklı şeftali çeşidinden BBCH ölçekleri kullanılarak çiçeklenme fenolojisi sekiz aşamaya ayrılmıştır. Web'e bağlı kameralar ve hava istasyonları, şeftali çeşitlerinden çiçek resimleri ve meteorolojik verileri otomatik olarak toplamıştır. Günlük değişkenler, resimlerde belirli renk aralıklarının alan oranı, sıcaklık, aydınlatma ve ısı/soğuma gereksinim verileri, dört ML modelinin (RF, SVM, Naive Bayes ve KNN) eğitilmesi ve test edilmesi için kullanılmıştır. Test kümesinde, RF modeli %98.82'lik en yüksek F1 puanını elde etmiştir. RF modeli aynı zamanda çiçek resimleri ve kamu meteorolojik verileri girdisi ile de kabul edilebilir doğruluk göstermektedir, bu da diğer ağaçlar veya tarım ürünlerinin fenolojisinin izlenmesi için modelin genelleştirilebilir olduğunu ortaya koymaktadır.

Şeftali meyvesine yönelik ML yöntemlerine dayalı sınıflandırma çalışmaları da bulunmaktadır. Bu çalışmalara örnek olarak El-Kahlout ve Abu-Naser (2020), şeftali ağaç görüntüleri içeren veri seti kullanarak ML'ye dayalı bir görüntü sınıflama çalışması gerçekleştirmişlerdir. Çalışmada, 2306 görsel içeren bir veri kümesi kullanılarak şeftali türlerinin belirlenmesi amaçlanmıştır. Veri kümesinde 1212 görsel eğitim için, 520 görsel doğrulama için ve 574 resim test için kullanılmıştır. Çalışmada görüntü tanıma için yaygın olarak kullanılan derin öğrenme teknikleri kullanılmıştır. Veri seti %70 eğitim, %30 doğrulama olacak şekilde ikiye ayrıştırılmıştır. Çalışmada önerilen model ayrı

bir test kümesinde %100'lük bir performans elde etmiştir. ML'ye dayalı desen ya da örüntü tanıma çalışmaları, bilgisayarla görme ya da bilgisayarlı görü alanında oldukça popülerdir. Bu çalışmalar neticesinde geliştirilen modeller, özellikle bitki çeşitlerinin tespiti için kullanılabilmektedir. Örneğin Wróbel ve diğerleri (2020) tarafından yapılan çalışmada, şeftali çeşitleri tanıma problemi ele alınarak ve bu konuda DNA tabanlı analizlere alternatifler aranmıştır. Çalışmada son yıllarda gelişen teknolojilerden bahsedilirken 3D tarayıcı teknolojisi temelli tamamen otomatik yaklaşımların veya 2D görüntü sınıflandırması için derin öğrenme yöntemlerinin kullanılma durumları tartışılmıştır. Çalışmanın uygulanabilirlik aşamasında, 2D görüntüler ve 3D taramalara dayanan yöntemlerin karşılaştırılmasına odaklanan çeşitli makine öğrenimi yaklaşımlarının potansiyelleri araştırılmıştır. Bir başka çalışmada, şeftali meyvesine ait çeşitleri belirlemek için ML'ye dayalı bir sistem geliştirilmiştir (Rong ve diğerleri, 2020). Çalışma beş şeftali çeşidi için yapılmış olup; her bir çeşit için 100 örnek alınmış ve toplamda 500 şeftali örneği oluşturulmuştur. Şeftali çeşitlerini analiz ederek sınıflandırmak için derin öğrenme prensibine dayanan bir tespit yöntemi önerilmiştir. Önerilen CNN tabanlı ağ modeli eğitim yoluyla elde edilmiştir ve test veri kümesi kullanılarak modelin başarısı ölçülmüştür. Derin öğrenmeye dayalı modelin doğrulama veri kümesinde %100 ve test veri kümesinde %94,4 doğrulukla çalıştığı bildirilmiştir.

Farklı ML modelleri kullanarak dört farklı şeftali türünü, şeftali yapraklarının üst ve alt yüzeylerinin dijital görüntülerinin renklerine dayalı olarak sınıflamayı amaçlayan bir çalışmada sınıflandırıcı ML modeli olarak SVM, RF ve çok katmanlı algılayıcı (MLP: Multi Level Perspective) modelleri kullanılmış ve performansları değerlendirilmiştir. Görüntü ön işleme süreçlerinin işe koşulduğu çalışmada renkli görüntülere ait farklı renk uzayları (RGB ve HSV) değerlendirilmiştir. Çalışmada HSV renk uzayının RGB'ye göre daha iyi performans sergilediği vurgulanırken; renk bilgilerini kullanan SVM sınıflandırıcısının, RF ve MLP'yi geride bırakarak en iyi sonuçları elde ettiği bildirilmiştir. SVM, %84,1'lik bir genel ortalama sınıflandırma doğruluğu elde etmiştir.

Şeftali meyvesine yönelik sertlik tahmini için doğru bir model oluşturmaya odaklanan bir çalışmada, birden çok makine öğrenimi modeli ve

bunların optimize edilmiş varyasyonları geliştirilip karşılaştırılmıştır (Ivanovski ve diğerleri, 2022). Çalışmada şeftali sertliğini tahmin etmek için çoklu doğrusal regresyon, regresyon ağaçları ve optimize edilmiş regresyon ağaçları modelleri kullanılmıştır.

Sahada meyve hastalıklarının geleneksel yöntemler kullanılarak takibi ve teşhisi zaman gerektiren yorucu bir süreç olabilmektedir. ML yöntemleri ve bilgisayarla görme teknikleri meyve hastalıklarının teşhisi ve tespiti için yaygın olarak kullanılabilmektedir (Hayıt ve diğerleri, 2018). Bu şekilde, üretilen gıda miktarını artırmaya ve ürün kayıplarını azaltmaya yardımcı olan sistemler üretilebilmektedir. Örneğin, Alosaimi ve diğerleri (2021) tarafından yapılan çalışmada, şeftali bitkilerindeki hastalıkları tespit edebilen yeni bir Evrişimsel Sinir Ağı (CNN: Convolutional Neural Network) modeli geliştirilmiştir. Önerilen yöntemle ayrıca hastalık bölgesi belirlenmiştir ve bu sayede çiftçilere şeftali mahsullerini korumak için uygun tedavileri bulmalarına yardımcı olabilecek bir sistem önerilmiştir. Şeftalilerdeki hastalıkların tespiti için VGG-19 mimarisi kullanılmıştır ve hastalık bölgelerinin lokalizasyonu için Mask R-CNN kullanılmıştır. Önerilen teknik, farklı teknikler kullanılarak değerlendirilmiş ve %94 doğruluk göstermiştir. Zhang ve diğerleri (2019) tarafından, şeftali yapraklarında görülen hastalıkları tespit etmek amacıyla CNN tabanlı bir yaklaşım önerilmiştir. Çalışmada önceden eğitilmiş CNN modeli olarak AlexNet, veri seti ile tekrar eğitilmiştir. Çalışmada AlexNet modelinin performansı geleneksel sınıflama yöntemleri olan SVM, KNN ve Geri Yayılım sinir ağı performansları ile karşılaştırılmıştır. Çalışma bulguları CNN'nin hastalıklı şeftali yapraklarını %100'lük bir doğrulukla tespit edebildiğini doğrulamıştır. Ayrıca diğer geleneksel yöntemlere göre daha iyi performans sergilediği bildirilmiştir.

Şeftali meyvesinde hastalık tespitine yönelik başka bir çalışmada, meyve ve yaprak görüntülerinde hastalıkları tespit etmek amacıyla CNN tabanlı hastalık tespit yöntemi geliştirilmiştir (Farman ve diğerleri, 2022). Birkaç ileri teknolojiyle eğitilmiş önceden eğitilmiş ağın özellik çıkarma süreçleri, optimal tespit performansı elde etmek için ince ayarlanmıştır. Şeftali bahçelerinden özel bir veri kümesi toplanmış ve veri artırım işlemi gerçekleştirilmiştir. Artırılmış veri kümesi, önceden eğitilmiş ağların öznitelik çıkarma süreçlerinin değiştirilerek ayarlanmasının etkilerini incelemek için kullanılmıştır. Özellikle

EfficientNet olmak üzere CNN modelleri, öznitelik çıkarma süreçleri ayarlandığında hedef veri kümesinde üstün performans sergilemiştir. Önerilen model, test görüntüleri üzerinde %96,6 ortalama doğruluk ve %90 hassasiyet ve kesinlik değerleri ile başarılı bir performans sergilemiştir.

Bakteri hastalıkları dünya genelinde şeftali üretimini etkileyen en yaygın ve yıkıcı hastalıklardır. Bu hastalıkların zamanında tespit edilmesi, tarım ilacı kullanımını azaltmak ve ürün kaybını önlemek için önem arz etmektedir. Bu kapsamda yapılan bir çalışmada, şeftali yaprak görüntülerinden hastalık tespiti için derin öğrenme ve görüntüleme yöntemi kullanılarak CNN modelleri geliştirilmiştir (Yadav ve diğerleri, 2021). Çalışmada önerilen model için eğitilecek veri seti bazı ön işleme süreçleri ile birlikte veri artırma işleminden geçirilmiştir. Farklı derin öğrenme algoritmalarıyla oluşturulan model mimarilerinden en iyi model, 0.185 saniyede %98.75 doğrulukla ilgili şeftali yaprağını (hastalıklı ve sağlıklı) başarılı bir şekilde ayırt edebilmiştir. Benzer olarak başka bir çalışmada hastalığı şeftali yapraklarında tespit etmek ve sınıflandırmak için yeni bir CNN modeli (WLNet) önerilmiştir (Akbar ve diğerleri, 2022). Önerilen model önceden eğitilmiş VGG-19 modeli geliştirilerek oluşturulmuştur. Çalışmada ilk olarak, 10000 adet görüntü içeren bir veri kümesi oluşturulmuştur. Bu görüntülerin 4500'ü hastalıklı, 5500'ü ise sağlıklı yaprakları temsil etmektedir. İkinci aşamada, görüntüler, hastalıklı ve sağlıklı yaprakların tespiti için bazı önişleme adımlarına tabi tutulmuştur (yeniden boyutlandırma, gürültü giderme, görüntü iyileştirme, arka plan kaldırma ve artırma). Son aşamada önerilen LWNet modeli yaprak sınıflandırması için eğitilmiştir. Model, LeNet, Alexnet, VGG-16 ve VGG-19 modelleriyle karşılaştırılmıştır. Önerilen model, %99'luk bir doğrulukla LeNet, Alexnet, VGG-16 ve VGG-19 modellerinden daha yüksek bir başarı elde etmiştir. Bu sonuçlar, önerilen modellerin şeftali yaprağı görüntüleri kullanılarak bakteriyel hastalıkların tespiti için etkili bir şekilde kullanılabileceğini göstermiştir.

Huang ve diğerleri (2020) çalışmalarında, şeftali hastalığı görüntülerindeki gürültü, arka plan ve düşük tespit sorunlarına odaklanmışlardır. Çalışmada öncelikle, ANLM görüntü gürültü giderme algoritması kullanılarak görüntüdeki karmaşık arka plan girişiminin azaltılması sağlanmaktadır. Daha sonra, çalışmada önerilen paralel CNN kullanılarak

şeftali hastalığının karakteristikleri belirlenmektedir. Son olarak, CNN ağında geleneksel softmax katmanının yerine, çalışma kapsamında önerilen doğrusal parçacık sürü optimizasyonu ile optimize edilmiş ELM kullanılmıştır. Bu iki iyileştirme ile, ağın yakınsama hızının ve doğruluğunun etkili bir şekilde artırıldığı belirtilmiştir. 25513 görüntü içeren veri seti kullanılarak gerçekleştirilen çalışmanın sonuçları, kahverengi çürüklük, siyah leke, antraknoz, yara ve normal şeftali sınıfları için en yüksek tespit doğruluğunun sırasıyla %89,02, %90,56, %85,37, %86,70 ve %89,91 olduğunu göstermiştir. Sonuçlar, önerilen yöntemlerin şeftali hastalığının tespiti için etkili bir yöntem olduğunu göstermektedir.

Şeftali hastalıklarının ML yöntemleri kullanılarak teşhis edilebilmesi kapsamında son zamanlarda yapılan çalışmalara örnek olarak, Zhang ve diğerleri (2023), Fastai Framework kullanarak CNN tabanlı entegre bir algoritma (CNN-F) geliştirmişlerdir. Geliştirilen algoritmanın test edilmesi için 2657 adet hastalıklı ve sağlıklı şeftali yaprak görüntüsü içeren veri seti kullanılmıştır. Çalışmada önerilen model için önceden eğitilmiş farklı CNN mimarileri (ResNet-34, AlexNet, VGG16 ve ResNet-50) kullanılmıştır. Bu modellerin sırasıyla %94.12, %91.12, %92.14 ve %93.23 doğruluk oranları ile performans sergiledikleri belirtilmiştir. Araştırma bulgularına göre ResNet-34 tabanlı önerilen CNN-F modelinin, hastalıklı şeftali yapraklarını teşhis etmek için kullanılabileceği kanıtlanmıştır.

1. SONUÇ

Bu çalışma, şeftali yetiştiriciliği alanında makine öğrenimi tekniklerinin uygulanabilirliğini ve etkinliğini incelemeyi amaçlamıştır. Yapılan incelemeler, makine öğreniminin şeftali yetiştiriciliği süreçlerinde önemli bir potansiyele sahip olduğunu ortaya koymaktadır. Bu teknikler, veri analizi, tahminler, karar destek sistemleri ve optimize edilmiş kaynak yönetimi gibi alanlarda çeşitli avantajlar sunmaktadır.

Çalışmanın literatür taraması, şeftali yetiştiriciliği süreçlerinde makine öğreniminin çeşitli aşamalarda uygulanabileceğini göstermektedir. Veri toplama aşamasında sensör verileri, hava durumu verileri ve toprak analizleri gibi verilerden yararlanarak daha kesin ve güvenilir sonuçlar elde edilebilir. Makine öğrenimi algoritmaları, bu verileri analiz ederek hastalık tahmini,

verim tahmini ve hasat zamanlaması gibi konularda değerli öngörüler sunabilir. Ayrıca, bu çalışma örneklerinde görüldüğü gibi, makine öğrenimi teknikleri tarım süreçlerini optimize etmede de etkili olabilir. Kaynakların daha etkin ve verimli kullanılmasına yönelik kararlar almak için algoritmalar kullanılabilir. Bu sayede su ve gübre gibi kaynakların israfı önlenirken verimlilik artırılabilir.

Sonuç olarak, bu çalışma şeftali yetiştiriciliği alanında makine öğreniminin potansiyelini ortaya koymayı amaçlamıştır. Literatürdeki örnekler ve incelemeler, bu tekniklerin şeftali yetiştiriciliği süreçlerini daha verimli, tahmin edilebilir ve sürdürülebilir hale getirmede önemli bir rol oynayabileceğini göstermektedir. Gelecekteki araştırmaların, daha spesifik problemleri çözmeye odaklanarak bu alandaki potansiyeli daha da genişletebileceği düşünülmektedir.

KAYNAKÇA

Abioye, E. A., Hensel, O., Esau, T. J., Elijah, O., Abidin, M. S. Z., Ayobami, A. S., ... & Nasirahmadi, A. (2022). Precision irrigation management using machine learning and digital farming solutions. AgriEngineering, 4(1), 70-103.

Akbar, M., Ullah, M., Shah, B., Khan, R. U., Hussain, T., Ali, F., ... & Kwak, K. S. (2022). An effective deep learning approach for the classification of bacteriosis in peach leave. Frontiers in Plant Science, 13, 4723.

Alosaimi, W., Alyami, H., & Uddin, M. I. (2021). PeachNet: Peach Diseases Detection for Automatic Harvesting. Computers, Materials & Continua, 67(2).

Aravatagimath, A., Sutagundar, A. V., & Yalavigi, V. (2021, December). Agriculture Product Marketing Data Analysis using Machine Learning. In 2021 International Conference on Forensics, Analytics, Big Data, Security (FABS) (Vol. 1, pp. 1-6). IEEE.

Ayala-Niño, D., & González-Camacho, J. M. (2022). Evaluation of machine learning models to identify peach varieties based on leaf color. Agrociencia.

Ayan, E., Erbay, H., & Varçın, F. (2020). Crop pest classification with a genetic algorithm-based weighted ensemble of deep convolutional neural networks. Computers and Electronics in Agriculture, 179, 105809.

Bini, D., Pamela, D., & Prince, S. (2020, March). Machine vision and machine learning for intelligent agrobots: A review. In 2020 5th International conference on devices, circuits and systems (ICDCS) (pp. 12-16). IEEE.

Brei, V. A. (2020). Machine learning in marketing: Overview, learning strategies, applications, and future developments. Foundations and Trends® in Marketing, 14(3), 173-236.

Chelliah, B. J., Latchoumi, T. P., & Senthilselvi, A. (2022). Analysis of demand forecasting of agriculture using machine learning algorithm. Environment, Development and Sustainability, 1-17.

Diao, G., Zhao, L., & Yao, Y. (2015). A dynamic quality control approach by improving dominant factors based on improved principal component analysis. International Journal of Production Research, 53(14), 4287-4303.

Domingues, T., Brandão, T., & Ferreira, J. C. (2022). Machine learning for detection and prediction of crop diseases and pests: A comprehensive survey. Agriculture, 12(9), 1350.

Durgabai, R. P. L., & Bhargavi, P. (2018). Pest management using machine learning algorithms: a review. International Journal of Computer Science Engineering and Information Technology Research (IJCSEITR), 8(1), 13-22.

Elavarasan, D., & Vincent, P. D. (2020). Crop yield prediction using deep reinforcement learning model for sustainable agrarian applications. IEEE access, 8, 86886-86901.

El-Kahlout, M. I., & Abu-Naser, S. S. (2020). Peach type classification using deep learning. International Journal of Academic Engineering Research (IJAER), 3(12).

Farman, H., Ahmad, J., Jan, B., Shahzad, Y., Abdullah, M., & Ullah, A. (2022). Efficientnet-based robust recognition of peach plant diseases in field images. Comput. Mater. Contin, 71, 2073-2089.

Ghadge, R., Kulkarni, J., More, P., Nene, S., & Priya, R. L. (2018). Prediction of crop yield using machine learning. Int. Res. J. Eng. Technol.(IRJET), 5, 2237-2239.

Gonzalez-Sanchez, A., Frausto-Solis, J., & Ojeda-Bustamante, W. (2014). Predictive ability of machine learning methods for massive crop yield prediction. Spanish Journal of Agricultural Research, 12(2), 313-328.

Gumiere, S. J., Camporese, M., Botto, A., Lafond, J. A., Paniconi, C., Gallichand, J., & Rousseau, A. N. (2020). Machine learning vs. physics-based modeling for real-time irrigation management. Frontiers in Water, 2, 8.

Hayıt, T. , Erbay, H. & Hayıt, F. (2018). Gıda Sektöründe Uygulanan Görüntü İşleme Çalışmalarının ve Tekniklerinin İncelenmesi. Electronic Letters on Science and Engineering, 14 (1) , 12-22.

Hayıt, T., Erbay, H., Varçın, F., Hayıt, F., & Akci, N. (2023). The classification of wheat yellow rust disease based on a combination of textural and deep features. Multimedia Tools and Applications, 1-19.

Hayit, T., Erbay, H., Varçın, F., Hayit, F., & Akci, N. (2021). Determination of the severity level of yellow rust disease in wheat by using convolutional neural networks. Journal of Plant Pathology, 103(3), 923-934.

Hsu, J. Y., Tseng, W. K., Hsieh, J. Y., Chang, C. J., & Chen, H. (2020). The recommending agricultural product sales promotion mode in e-Commerce using reinforcement learning with contextual multiarmed bandit algorithms. Mathematical Problems in Engineering, 2020, 1-10.

Huang, S., Zhou, G., He, M., Chen, A., Zhang, W., & Hu, Y. (2020). Detection of peach disease image based on asymptotic non-local means and PCNN-IPELM. IEEE Access, 8, 136421-136433.

Ivanovski, T., Zhang, X., Jemrić, T., Gulić, M., & Matetić, M. (2022). Peach Firmness Prediction Using Optimized Regression Trees Models. Annals of DAAAM & Proceedings, 33.

Karpatne, A., Jiang, Z., Vatsavai, R. R., Shekhar, S., & Kumar, V. (2016). Monitoring land-cover changes: A machine-learning perspective. IEEE Geoscience and Remote Sensing Magazine, 4(2), 8-21.

Kumar, I., Rawat, J., Mohd, N., & Husain, S. (2021). Opportunities of artificial intelligence and machine learning in the food industry. Journal of Food Quality, 2021, 1-10.

Kumar, N., Mastrangelo, C., & Montgomery, D. (2011). Hierarchical modeling using generalized linear models. Quality and Reliability Engineering International, 27(6), 835-842.

Leitzke Betemps, D., Vahl de Paula, B., Parent, S. É., Galarça, S. P., Mayer, N. A., Marodin, G. A., ... & Brunetto, G. (2020). Humboldtian diagnosis of peach tree (prunus persica) nutrition using machine-learning and compositional methods. Agronomy, 10(6), 900.

Ljubobratović, D., Vuković, M., Brkić Bakarić, M., Jemrić, T., & Matetić, M. (2022). Assessment of various machine learning models for peach maturity prediction using non-destructive sensor data. Sensors, 22(15), 5791.

Ljubobratović, D., Vuković, M., Brkić Bakarić, M., Jemrić, T., & Matetić, M. (2021). Utilization of explainable machine learning algorithms for determination of important features in 'Suncrest'peach maturity prediction. Electronics, 10(24), 3115.

Ljubobratović, D., Zhang, G., Brkić Bakarić, M., Jemrić, T., & Matetić, M. (2020, October). Predicting peach fruit ripeness using explainable machine learning. In Proceedings of the 31st International DAAAM Symposium (pp. 717-723).

Mohanty, S. N., Chatterjee, J. M., Jain, S., Elngar, A. A., & Gupta, P. (Eds.). (2020). Recommender system with machine learning and artificial intelligence: practical tools and applications in medical, agricultural and other industries. John Wiley & Sons.

Okan, N. ve Engindeniz, S. (2016). İzmir'in Selçuk İlçesindeki Şeftali Bahçelerinin Gelir Yöntemiyle Değerlemesi Üzerine Bir Araştırma. Ege Üniversitesi Ziraat Fakültesi Dergisi, 53 (2) , 139-146. DOI: 10.20289/zfdergi.388861

Paudel, D., Boogaard, H., de Wit, A., Janssen, S., Osinga, S., Pylianidis, C., & Athanasiadis, I. N. (2021). Machine learning for large-scale crop yield forecasting. Agricultural Systems, 187, 103016.

Rong, D., Wang, H., Ying, Y., Zhang, Z., & Zhang, Y. (2020). Peach variety detection using VIS-NIR spectroscopy and deep learning. Computers and Electronics in Agriculture, 175, 105553.

Saleem, M. H., Potgieter, J., & Arif, K. M. (2021). Automation in agriculture by machine and deep learning techniques: A review of recent developments. Precision Agriculture, 22, 2053-2091.

Shaikh, T. A., Rasool, T., & Lone, F. R. (2022). Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. Computers and Electronics in Agriculture, 198, 107119.

Sujjaviriyasup, T., & Pitiruek, K. (2013). Agricultural product forecasting using machine learning approach. Int. Journal of Math. Analysis, 7(38), 1869-1875.

Vural, H. ve Çakan, V. A. (2021). Türkiye şeftali piyasasının ekonomik analizi ve pazarlama marjları. Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi, 24(2), 379-387.

Wani, H., & Ashtankar, N. (2017, January). An appropriate model predicting pest/diseases of crops using machine learning algorithms. In 2017 4th International Conference on Advanced Computing and Communication Systems (ICACCS) (pp. 1-4). IEEE.

Wróbel, A., Gygax, G., Schmid, A., & Ott, T. (2020). Going for 2D or 3D? Investigating Various Machine Learning Approaches for Peach Variety Identification. In Artificial Neural Networks in Pattern Recognition: 9th IAPR TC3 Workshop, ANNPR 2020, Winterthur, Switzerland,

September 2–4, 2020, Proceedings 9 (pp. 257-265). Springer International Publishing.

Yadav, S., Sengar, N., Singh, A., Singh, A., & Dutta, M. K. (2021). Identification of disease using deep learning and evaluation of bacteriosis in peach leaf. Ecological Informatics, 61, 101247.

Yuh, Y. G., Tracz, W., Matthews, H. D., & Turner, S. E. (2023). Application of machine learning approaches for land cover monitoring in northern Cameroon. Ecological Informatics, 74, 101955.

Zhang, D., Yang, H., Cao, J., Gong, Q., & Kumaran, S. R. (2023). Peach Leaf Diseases Identification Using Convolutional Neural Network and Fastai Framework.

Zhang, J., & Ye, C. (2022, August). A Peach Maturity Detection Algorithm Based on YOLOV5 Attention Mechanism. In 2022 International Conference on Machine Learning and Intelligent Systems Engineering (MLISE) (pp. 284-287). IEEE.

Zhang, K., Xu, Z., Dong, S., Cen, C., & Wu, Q. (2019). Identification of peach leaf disease infected by Xanthomonas campestris with deep learning. Engineering in Agriculture, Environment and Food, 12(4), 388-396.

Zhou, Z. H. (2021). Machine learning. Springer Nature.

Zhu, Y., Chen, M., Gu, Q., Zhao, Y., Zhang, X., Sun, Q., ... & Zheng, K. (2022). Machine learning methods for efficient and automated in situ monitoring of peach flowering phenology. Computers and Electronics in Agriculture, 202, 107370.