Turkish Journal of Agriculture - Food Science and Technology, 14(9):2516-2527, 2026
DOI: https://doi.org/10.24925/turjaf.v14i9.2516-2527.9004

Turkish Journal of Agriculture - Food Science and Technology

Available online, ISSN: 2148-127X | www.agrifoodscience.com | Turkish Science and Technology Publishing (TURSTEP)

Classification of Pistachio Varieties Using Metaheuristic Optimization: A Comparative Study

Ali Özarslan[1,a,*]

[1]*Hacettepe Üniversitesi, Rektörlük, 06800, Çankaya, Ankara, Türkiye*
[*]*Corresponding author*

ARTICLE INFO

Research Article

Received : 20.04.2026
Accepted : 11.07.2026

Keywords:
Pistachio
Machine learning
Metaheuristic optimization
Hyperparameter optimization
Classification

ABSTRACT

This study addresses the classification of two commercially important pistachio varieties, Kirmizi and Siirt, cultivated extensively in Turkey. The objective is to evaluate the effectiveness of metaheuristic optimization for improving machine learning classifier performance in agricultural product discrimination. A dataset of 2148 images was used to extract 28 morphological, color, and texture features. Class imbalance was mitigated using the Synthetic Minority Over-sampling Technique. Logistic Regression, Support Vector Machine (SVM), and XGBoost classifiers were applied. Hyperparameters of these classifiers were optimized using six metaheuristic algorithms: Particle Swarm Optimization, Artificial Bee Colony, Swift Flight Optimizer, Tardigrade Optimization Algorithm, Bilby Optimization Algorithm (BOA), and Schrödinger Optimizer (SCO). Models were evaluated using 5-fold cross-validation on the training set and tested on an independent test set. Results indicate that BOA combined with SVM achieved the highest classification accuracy. The best discriminative power, measured by the area under the ROC curve, was obtained with SCO combined with XGBoost. Compared to default parameter configurations, metaheuristic optimization led to notable improvements in both SVM and XGBoost classifiers. The findings demonstrate that metaheuristic-based hyperparameter optimization provides an effective and competitive approach for automatic pistachio variety discrimination, offering practical potential for deployment in agricultural sorting and quality control systems.

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 14(9):2516-2527, 2026

Antep Fıstığı Türlerinin Metasezgisel Optimizasyon ile Sınıflandırılması: Karşılaştırmalı Bir Çalışma

MAKALE BİLGİSİ

Araştırma Makalesi

Geliş : 20.04.2026
Kabul : 11.07.2026

Anahtar Kelimeler:
Antep fıstığı
Makine öğrenmesi
Metasezgisel optimizasyon
Hiperparametre optimizasyonu
Sınıflandırma

ÖZ

Bu çalışma, Türkiye'de yaygın olarak yetiştirilen iki ticari Antep fıstığı türü olan Kırmızı ve Siirt'in sınıflandırılmasını ele almaktadır. Amaç, tarımsal ürün ayrımında makine öğrenmesi sınıflandırıcılarının performansını iyileştirmede metasezgisel optimizasyonun etkinliğini değerlendirmektir. 2148 görüntüden 28 morfolojik, renk ve doku özniteliği çıkarılmıştır. Sınıf dengesizliği Sentetik Azınlık Aşırı Örnekleme Tekniği ile giderilmiştir. Lojistik Regresyon, Destek Vektör Makinesi (SVM) ve XGBoost sınıflandırıcıları uygulanmıştır. Bu sınıflandırıcıların hiperparametreleri Parçacık Sürü Optimizasyonu, Yapay Arı Kolonisi, Hızlı Uçuş Optimize Edici, Tardigrat Optimizasyon Algoritması, Bilby Optimizasyon Algoritması (BOA) ve Schrödinger Optimize Edici (SCO) olmak üzere altı metasezgisel algoritma ile optimize edilmiştir. Modeller eğitim setinde 5 katlı çapraz doğrulama ile değerlendirilmiş ve bağımsız test setinde test edilmiştir. Sonuçlar, en yüksek sınıflandırma doğruluğunun BOA ile optimize edilmiş (SVM) modelinde elde edildiğini göstermektedir. En yüksek ayırt edicilik gücü (ROC eğrisi altında kalan alan) ise SCO ile optimize edilmiş XGBoost modelinde gözlenmiştir. Varsayılan parametre yapılandırmalarıyla karşılaştırıldığında, metasezgisel optimizasyonun hem SVM hem de XGBoost sınıflandırıcılarında kayda değer iyileşmeler sağladığı belirlenmiştir. Bulgular, metasezgisel tabanlı hiperparametre optimizasyonunun Antep fıstığı türlerinin otomatik ayrımında etkili ve rekabetçi bir yaklaşım sunduğunu ve tarımsal ayıklama ile kalite kontrol sistemlerinde kullanılma potansiyeli taşıdığını göstermektedir.

[a] *aliozarslan@hacettepe.edu.tr* *https://orcid.org/0000-0002-9407-1787*

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

Giriş

Antep fıstığı (Pistacia vera L.), dünyanın en önemli sert kabuklu meyvelerinden biri olup, Orta Doğu, Orta Asya, Akdeniz havzası ile artan ölçüde Amerika Birleşik Devletleri ve Avustralya'nın kurak ve yarı kurak bölgelerinde yaygın olarak yetiştirilmektedir. Küresel Antep fıstığı üretimi, son yıllarda artan tüketici talebi, belgelenmiş sağlık yararları ve şekerleme, mutfak endüstrisindeki yüksek pazar değeri sayesinde yıllık 700.000 tonu aşarak dikkat çekici bir yükseliş göstermiştir (FAO, 2023; Dreher, 2012). Ticari Antep fıstığı yetiştiriciliğinde, çeşit tanıma ve kalite sınıflandırması, pazar fiyatlandırmasını, işleme verimliliğini ve tüketici memnuniyetini doğrudan etkileyen kritik zorluklar arasında yer almaktadır. Özellikle Türkiye üretiminde baskın olan Kırmızı ve Siirt çeşitleri arasındaki ayrım, geleneksel olarak eğitimli uzmanlar tarafından yapılan manuel incelemeye dayanmaktadır. Bu süreç, doğası gereği insan yorgunluğuna, değerlendiriciler arası değişkenliğe ve büyük ölçekli endüstriyel ortamlarda iş hacminin pratik sınırlamalarına tabidir (Ozkan ve ark., 2021).

Tarımsal ürünlerin doğru ve hızlı sınıflandırılması, yalnızca üretici ve tüketici arasında ticari adaleti sağlamakla kalmaz; aynı zamanda hasat sonrası kayıpları azaltarak gıda israfını önler, katma değeri yüksek ürünlerin doğru pazarlara ulaşmasına imkân tanır ve sürdürülebilir tarım politikalarının etkin bir şekilde yürütülmesine katkıda bulunur. Bu nedenle otomatik sınıflandırma sistemlerinin geliştirilmesi, tarım sektöründe hem mikro düzeyde işletme verimliliği hem de makro düzeyde gıda güvenliği açısından stratejik bir gerekliliktir.

Bilgisayarlı görü ve makine öğrenmesi (ML) teknolojilerinin ortaya çıkışı, tarımsal ürün sınıflandırması ve kalite değerlendirmesinin otomasyonu için dönüştürücü yollar açmıştır (Liakos ve ark., 2018). Antep fıstığı çeşitlerini yüksek doğrulukla ayırt edebilen görüntü tabanlı sınıflandırma sistemleri önemli pratik faydalar sunmaktadır: üretim hatlarında gerçek zamanlı ayıklamayı mümkün kılar, pahalı uzman iş gücüne olan bağımlılığı azaltır, izlenebilirlik ve etiketleme uyumunu iyileştirir ve veri odaklı ıslah ve tarım araştırmalarını kolaylaştırır (Mohanty ve ark., 2016). Antep fıstığı görüntülerine gömülü olan görsel morfolojik özellikler (şekil parametreleri, renk histogramları, doku tanımlayıcıları ve uzamsal moment tabanlı öznitelikler), ML yöntemlerince kullanılabilecek zengin ve ayırt edici bir bilgi alanı sağlamaktadır.

ML tabanlı yaklaşımların bariz potansiyeline rağmen bunların Antep fıstığı çeşitlerinin ayrımında etkin bir şekilde kullanılmasını zorlaştıran çeşitli güçlükler bulunmaktadır. Olgunluk aşaması, çevresel yetiştirme koşulları ve hasat sonrası işlemedeki farklılıklardan kaynaklanan yüksek sınıf içi görsel değişkenlik, tek bir öznitelik tanımlayıcısının veya sınıflandırıcı mimarisinin evrensel olarak baskın olmadığı anlamına gelmektedir. Ayrıca, Destek Vektör Makineleri (SVM), Rastgele Orman (RF), k-En Yakın Komşu (k-NN), Lojistik Regresyon (LR) ve Karar Ağaçları (DT) gibi klasik ML sınıflandırıcılarının performansı, hiperparametrelerin seçimine ve ayarlanmasına, ham görüntü verilerine uygulanan ön işleme zincirine ve model eğitimi için seçilen öznitelik alt kümesine güçlü bir şekilde bağlıdır. Bu nedenle, Izgara Arama ve Rastgele Arama çapraz doğrulama gibi sistematik hiperparametre optimizasyonu stratejileri, raporlanan sınıflandırıcı karşılaştırmalarının her bir yöntemin gerçek ayırt edici potansiyelini yansıtmasını sağlamak için olmazsa olmazdır (Bergstra & Bengio, 2012; Probst ve ark., 2019).

Metasezgisel algoritmalar, türev alınamayan, ayrık ve çok kipli problemlere uygulanabilen popülasyon tabanlı arama yöntemleridir. Bu algoritmalar, büyük ve karmaşık parametre uzaylarını yüksek verimlilikle tarayarak optimum ya da optimuma yakın çözümler bulmayı hedeflemektedir (Yang ve Shami, 2020). "Bedava Öğle Yemeği Yok" (No Free Lunch) teoremi, hiçbir algoritmanın tüm optimizasyon problemlerinde evrensel üstünlük sağlayamayacağını öngörmekte ve bu durum araştırmacıları farklı problemler için çeşitli algoritmalar geliştirmeye yönlendirmektedir (Wolpert ve Macready, 1997).

Bu çalışma, yukarıda bahsedilen zorlukları, Kırmızı ve Siirt Antep fıstığı çeşitlerinin otomatik ayrımı için çapraz doğrulamalı hiperparametre optimizasyonu ile optimize edilmiş çoklu ML sınıflandırıcısının karşılaştırmalı incelemesi yoluyla ele almaktadır. Standartlaştırılmış bir Antep fıstığı görüntü veri setinden çıkarılan morfolojik, renk, şekil ve doku özellikleri, öznitelik temsil alanı olarak kullanılmıştır. Karşılaştırmalı çerçeve, hangi sınıflandırıcı ailelerinin bu spesifik tarımsal sınıflandırma problemine uygulandığında üstün doğruluk, genellenebilirlik ve hesaplama verimliliği sunduğunu belirlemeyi amaçlamaktadır. Bulgular, Antep fıstığı işleme tesislerinde otomatik ayıklama sistemleri kuran uygulayıcılar için eyleme dönüştürülebilir bir rehberlik sağlamayı ve daha geniş gıda ve tarımsal ürün sınıflandırması alanında çalışan araştırmacılar için metodolojik bir kıyaslama sunmayı hedeflemektedir.

Makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2, Antep fıstığı sınıflandırması üzerine önceki çalışmaları, tarımsal ürün ayrımında ML uygulamalarını ve ML sınıflandırıcıları için optimizasyon stratejilerini kapsayan kapsamlı bir literatür taraması sunmaktadır. Bölüm 3, veri setini ve deneysel tasarımı açıklamaktadır. Bölüm 4, sınıflandırıcılar arasındaki karşılaştırmalı sonuçları sunmakta ve Bölüm 5, bulguların sonuçları ve gelecekteki araştırmalar için yönler üzerine bir tartışma ile sona ermektedir.

Literatür Taraması

Tarımsal Ürün Sınıflandırmasında Derin Öğrenme

Derin öğrenmenin tarımsal ürünlerin sınıflandırılmasına uygulanması, 2000'li yılların başından itibaren canlı bir araştırma alanı olmuştur. Erken dönem çalışmalar, iki boyutlu görüntülerden çıkarılan morfolojik ve renk özelliklerinin, sınıflandırma görevlerinde insan uzman yargısının yerine geçebilecek etkili vekiller olarak hizmet edebileceğini göstermiştir. Sonmez ve ark. (2024), buğday çeşitleri ve melezlerini sınıflandırmak için MobileNetv2 ve GoogleNet derin öğrenme modellerini kullanmıştır. Modellerin doğrudan sınıflandırma başarıları sırasıyla %99,26 ve %97,41 olarak raporlanırken,

MobileNetv2 modelinden çıkarılan derin özniteliklerin SVM ile sınıflandırılmasıyla bu başarı %99,91'e yükseltilmiştir. Benzer yaklaşımlar, pirinç çeşidi ayrımı (Saranwong ve ark., 2004), elma sınıflandırması (Leemans ve ark., 2002) ve domates kalite ayıklaması (Blasco ve ark., 2007) üzerinde uygulanmış ve görüntü tabanlı ML hatlarının gerçek dünya tarımsal uygulamaları için uygulanabilirliğini doğrulamıştır.

Mohanty ve ark. (2016), 26 hastalık ve 14 bitki türü arasında bitki hastalığı tespiti için derin evrişimli sinir ağlarından (CNN) yararlanmış ve ayrılmış test kümelerinde %99'un üzerinde doğruluk oranına ulaşarak, büyük ölçekli görüntü veri tabanlarından (örneğin ImageNet) transfer öğrenmenin, alana özgü tarımsal görevler için veri gereksinimlerini önemli ölçüde azaltabileceğini göstermiştir. Ferentinos (2018), bu araştırmayı daha geniş bir bitki patolojileri yelpazesine genişleterek, büyük, iyi açıklamalı veri kümeleri mevcut olduğunda derin öğrenmenin geleneksel ML yöntemlerinden tutarlı bir şekilde daha iyi performans gösterdiği sonucunu pekiştirmiştir.

Son dönem karşılaştırmalı analizler, özellikle küçük ila orta boyutlu veri kümeleri, sınırlı hesaplama kaynakları veya iyi hazırlanmış alana özgü öznitelik tanımlayıcılarının mevcudiyeti ile karakterize edilen ortamlarda, derin öğrenmenin evrensel olarak üstün olduğu varsayımına meydan okumuştur. Bu bağlamlarda, özellikle SVM'ler ve topluluk tabanlı yaklaşımlar olmak üzere klasik ML yöntemleri, önemli ölçüde daha düşük hesaplama yükü ile genellikle rekabetçi veya üstün performans göstermektedir (LeCun ve ark., 2015; Vapnik, 2013). Kuru üzüm gibi tarımsal ürünlerin sınıflandırılmasını inceleyen Raihen ve Akter (2023), görüntülerden elde edilen morfolojik özniteliklerle beslenen SVM, Karar Ağacı, k-NN, RF ve XGBoost başta olmak üzere birden fazla ML yöntemi karşılaştırmalı olarak ele alınmıştır. ML algoritmalarının, öznitelik bazlı yapılandırılmış verileri işlemede derin öğrenme yaklaşımlarına kıyasla rekabetçi ve yorumlanabilir sonuçlar sunduğu görülmektedir.

Tarımsal Ürün Sınıflandırmasında ML uygulamaları

Tarımsal ürün sınıflandırması görevlerinde yapılan karşılaştırmalı çalışmalar, LR'nin rekabetçi performansını ortaya koymaktadır. Örneğin, bir ürün öneri sisteminde LR %93,15 doğruluk oranına ulaşarak RF'nin (%94,51) hemen ardında ikinci en başarılı yöntem olarak değerlendirilmiştir (Qanith ve Khilar, 2025). Uzaktan algılama görüntülerinde ürün türü tanımlama görevinde ise ağ düzenlileştirmeli seyrek LR modeli, kışlık buğday ve kışlık kanola için sırasıyla 0,982 ve 0,972 genel doğruluk elde ederek yüksek performans sergilemiştir (Wei ve ark., 2025).

SVM (Cortes ve Vapnik, 1995), tarımsal ürün sınıflandırmasında yapısal risk minimizasyonu teorisi, çekirdek hilesi ile yüksek boyutlu uzaylarda maksimum ayırıcı hiperdüzlemler inşa edebilme yeteneği ve boyutluluk lanetine karşı gösterdiği göreli sağlamlık sayesinde güçlü bir performans sergilemiştir. Huang ve ark. (2002), uzaktan algılama bitki örtüsü sınıflandırmasında SVM'leri YSA ve DT ile karşılaştırmış; SVM'lerin özellikle küçük örneklem durumlarında görünmeyen görüntülere daha etkili genellediğini bulmuştur. Nandi ve ark. (2013) tarafından pirinç tanesi sınıflandırmasında yapılan benzer bir çalışma, SVM'lerin k-NN, LDA ve DT'yi hem doğruluk hem de hesaplama verimliliği açısından geride bıraktığını doğrulamıştır. SVM performansı üzerinde çekirdek fonksiyonu seçimi ve ilişkili parametrelerin (özellikle düzenlileştirme katsayısı C ve çekirdek parametresi γ) belirleyici etkisi bulunmaktadır. Kötü ayarlanmış SVM'ler yetersiz öğrenme veya aşırı öğrenme sorunları yaşayabileceğinden, çapraz doğrulamalı ızgara arama, tarımsal ML literatüründe standart hiperparametre optimizasyonu yöntemi olarak kullanılmaya devam etmektedir (Bergstra ve Bengio, 2012).

Gradyan artırma algoritmaları, özellikle XGBoost, ardışık her bir öğreniciyi seleflerinin kalıntı hatalarına uyarlayarak toplulukları sırayla inşa eder. Bu yöntemler, yapılandırılmış veri sınıflandırması kıyaslamalarında en yüksek doğruluk seviyelerine ulaşmış ve gıda kalite değerlendirmesi gibi alanlarda sınıf dengesizliği ile öznitelik etkileşimlerini tek modelli sınıflandırıcılardan daha etkili şekilde ele aldıkları gösterilmiştir (Chen ve Guestrin, 2022). Örneğin, tarımsal ürün deseni sınıflandırması üzerine yapılan bir çalışmada, XGBoost algoritması RF (%89,15), SVM (%86,14) ve ANN (%85,48) gibi diğer ML yöntemlerine kıyasla %92,14 ile en yüksek genel doğruluk oranına ulaşmıştır (Şimşek, 2025).

Hiperparametre Optimizasyonu ve Metasezgisel Yaklaşımlar

ML sınıflandırıcılarının hiperparametre optimizasyonu, adil ve tekrarlanabilir karşılaştırmalar için kritik ancak sıklıkla ihmal edilen bir bileşendir. Varsayılan hiperparametrelerle yapılan karşılaştırmalar yanıltıcı olabilir; zira varsayılan yapılandırmalar genel problemler için kalibre edilmiştir ve tarımsal görüntü sınıflandırması gibi spesifik görevlerde optimal performansı vermeyebilir (Bergstra ve Bengio, 2012). Izgara Arama Çapraz Doğrulama (GS-CV), kavramsal basitliği nedeniyle yaygın olmakla birlikte, hiperparametre sayısı arttıkça hesaplama maliyeti üstel olarak artar. Bu nedenle uygulayıcılar, optimum bölgeleri kaçırma riski taşıyan kaba ızgara yaklaşımlarına yönelmişlerdir (Larochelle ve ark., 2007).

Rastgele Arama (RS), GS-CV'ye hesaplama açısından verimli bir alternatif olup, hiperparametrelerin yalnızca küçük bir alt kümesinin performans üzerinde etkili olduğu varsayımıyla, rastgele örnekleme yaparak daha az değerlendirme ile optimuma yakın sonuçlar elde etmektedir (Bergstra ve Bengio, 2012). Bayesçi Hiperparametre Optimizasyonu (BO) ise daha sofistike bir yaklaşımla, önceki değerlendirmelerden öğrenerek olasılıksal bir vekil model oluşturur ve umut vaat eden bölgelere yönlendirir. Optuna gibi çerçevelerle uygulanan BO yöntemleri, eşit bütçelerde hem GS-CV hem de RS'den tutarlı şekilde üstün performans sergiler (Snoek ve ark., 2012; Falkner ve ark., 2018). Bülbül ve ark. (2026) tarafından yapılan bir çalışmada ise makine öğrenmesi algoritmalarını entegre eden çift modüllü bir tarımsal karar destek sistemi önerilmiş; ürün öneri modülünde RF ile %99,32, gübre öneri modülünde %98,75 doğruluk elde edilmiştir. Bu sistem, sınıf dengesizliğini gidermek için SMOTE (Sentetik Azınlık Aşırı Örnekleme Tekniği) ve

hiperparametre optimizasyonu için GridSearchCV gibi teknikleri içermektedir.

Hiperparametre ayarının tarımsal ürün sınıflandırmasındaki etkisine ilişkin araştırmalar sınırlı olmakla birlikte, diğer alanlarda kapsamlı bir birikim oluşmuştur. Genetik Algoritma (GA) ve Parçacık Sürü Optimizasyonu (PSO) gibi metasezgisel algoritmaların çeşitli model hiperparametreleriyle optimize edildiği çalışmalarda, bu tekniklerin ızgara aramaya kıyasla hesaplama etkinliği açısından belirgin üstünlükler sağladığı gösterilmektedir (Yang ve Shami, 2020). SVM hiperparametrelerinin optimize edildiği karşılaştırmalı bir çalışmada PSO'nun rekabetçi sonuçlar verdiği raporlanmıştır (Rizkallah, 2025). Mehdary ve ark. (2024), GA ile XGBoost modelini birleştirerek doğruluğu 0,82'den 0,978'e yükseltmiş ve metasezgisel hiperparametre optimizasyonunun dönüştürücü etkisini somut biçimde ortaya koymuştur. Lima Marinho ve ark. (2024), meta-özelliklere dayalı XGBoost hiperparametre önerilerinin varsayılan konfigürasyonlara kıyasla çoğunlukla daha iyi sonuçlar ürettiğini göstermiştir.

Antep Fıstığı Çeşitlerinin Sınıflandırılması Üzerine Çalışmalar

Derin öğrenme tabanlı Antep fıstığı çeşitlerinin ayrımını hedefleyen araştırmalardan Singh ve ark. (2022), Ozkan ve ark. (2021) çalışması tarafından oluşturulan 16 morfolojik, şekil ve renk özelliği içeren Antep fıstığı veri seti üzerinde AlexNet, VGG16 ve VGG19 mimarileriyle derin öğrenme yaklaşımı uygulamış; VGG16 modeli %98,84 doğruluk ile en yüksek başarıya ulaşırken, bu kazanımlar uzun eğitim süreleri ve yüksek hesaplama maliyeti gerektirmiştir. Uzer (2025), aynı veri seti üzerinde sekiz farklı CNN modelini 5 katlı çapraz doğrulama ile değerlendirmiş; ResNet-50 modeli %99,63 ortalama doğruluk ile en yüksek başarıya ulaşmıştır.

Aktaş (2022), Antep fıstıklarının dış kabuk rengine göre sınıflandırılması amacıyla 3983 görüntü üzerinden derin öğrenme temelli bir yaklaşım önermiş ve AlexNet mimarisi ile %98,44 doğruluk elde etmiştir. Kumar ve ark. (2023) ise farklı bir yaklaşımla, derin sinir ağları ile görüntülerden vektör temsilleri çıkarmış ve bu öznitelikleri küçük ölçekli makine öğrenmesi algoritmaları ile sınıflandırmıştır. Çalışmada, VGG-16, ResNet gibi ön eğitimli bir CNN'nin ikinci son katmanından çıkarılan özniteliklerle eğitilen LR modeli %97,20 doğruluk oranına ulaşmıştır.

Makine öğrenmesi tabanlı Antep fıstığı çeşitlerinin ayrımını hedefleyen araştırmalar, daha geniş tarımsal ürün sınıflandırması literatürüne kıyasla nispeten sınırlı kalmış olsa da, birkaç önemli katkı önemli deneysel taban çizgileri oluşturmuştur. Geleneksel makine öğrenmesi yaklaşımlarına bakıldığında Ozkan ve ark. (2021), 16 morfolojik, şekil ve renk özelliği içeren Antep fıstığı veri setini kullanarak SVM, RF, k-NN gibi klasik sınıflandırıcılarla en yüksek doğruluğu (%94,2) RBF çekirdekli SVM ile elde etmiştir.

Mahdavi-Jafari ve ark. (2008), Antep fıstıklarını açık kabuklu, dolu-kapalı ve boş-kapalı olmak üzere üç sınıfa ayıran akıllı bir sistem geliştirmiş; YSA, çelik levhaya çarpan fıstıkların akustik sinyallerinin analizine dayalı biçimde eğitilmiş ve %99,89 doğruluk oranına ulaşılmıştır. Omid ve ark. (2017), soyulmuş Antep fıstığı çekirdeklerini beş kalite sınıfına göre ayırmak amacıyla renk ve şekil öznitelikleriyle beslenen YSA ve SVM sınıflandırıcılarını birlikte ele almış; sırasıyla %99,4 ve %99,88 doğruluk elde etmişlerdir. Vidyarthi ve ark. (2020) ise Antep fıstığı çekirdeklerinin büyüklük ve ağırlığını tahmin etmek amacıyla RF tekniğini uygulamış ve güvenilir istatistiksel sonuçlar elde etmiştir. Farklı bir yaklaşımla Turkay ve Tamay (2024), açık ve kapalı kabuklu Antep fıstıklarını ayırt etmek için akustik emisyon sinyallerinden Mel frekansı kepstrum katsayıları ile öznitelik çıkarmış ve SVM ile sınıflandırarak açık kabuklular için %97,2; kapalı kabuklular için %97,95 doğruluk elde etmiştir.

Literatürdeki Boşluklar ve Çalışmanın Katkısı

Mevcut araştırmalar bir bütün olarak değerlendirildiğinde, önemli boşlukların varlığı dikkat çekmektedir. Birincisi, Antep fıstığı sınıflandırması üzerine gerçekleştirilen çalışmaların büyük çoğunluğu, son kullanıcı uygulamalarında hesaplama gücü ve yorumlanabilirlik açısından sınırlılıklar içeren derin öğrenme mimarilerine yoğunlaşmıştır. İkincisi, el ile çıkarılan morfolojik, renk ve doku özniteliklerini kullanan ML yaklaşımları üzerine yapılan çalışmalarda hiperparametre optimizasyon stratejileri sistematik biçimde ele alınmamıştır. Son olarak, birden fazla metasezgisel algoritmanın ML sınıflandırıcı parametrelerini optimize etme kapasitesinin karşılaştırmalı olarak değerlendirildiği araştırmalar son derece sınırlıdır.

Bu çalışma, söz konusu boşlukları birbiriyle bütünleşik birkaç özgün katkı ile doldurmayı hedeflemektedir. Birincisi, altı farklı metasezgisel algoritmanın her biri için üç farklı sınıflandırıcının hiperparametrelerini sistematik biçimde optimize etmek amacıyla aynı çerçeve altında uygulanmıştır. İkincisi, farklı düzeylerde olgunluğa sahip algoritmalar incelenerek yeni nesil metasezgisel yöntemlerin klasik metasezgisel yaklaşımlara kıyasla hiperparametre optimizasyonundaki göreceli etkinliği değerlendirilmiştir. Son olarak, SMOTE tabanlı sınıf dengeleme, çapraz doğrulama ve bağımsız test seti değerlendirmesi içeren sağlam bir deneysel protokol uygulanarak sınıflandırma tahminlerinin güvenilirliği güvence altına alınmıştır. Bu bütünleşik yaklaşım, tarımsal ürün sınıflandırması için metasezgisel tabanlı hiperparametre optimizasyonuna ilişkin değerli ve yeniden kullanılabilir bir metodolojik çerçeve sunmaktadır.

Veri ve Metotlar

Veri Seti

Bu çalışmada kullanılan veri seti, Türkiye'de yaygın olarak yetiştirilen ve ticari değeri yüksek iki Antep fıstığı türü olan Kırmızı ve Siirt çeşitlerine ait Ozkan ve ark. (2021) tarafından oluşturulan görüntülerden oluşturulmuştur. Görüntüler, özel olarak tasarlanmış bir bilgisayarlı görü sistemi kullanılarak Prosilica GT2000C model bir kamera ile 2048×1088 piksel çözünürlükte elde edilmiştir. Görüntüleme işlemi sırasında dış ortam ışığının etkisini en aza indirmek ve gölgelenmeyi önlemek amacıyla özel bir ışık kutusu ve siyah zemin kullanılmış, kamera ile örnekler arasındaki mesafe 15 cm olarak sabitlenmiştir (Ozkan ve ark., 2021).

Ozkan ve ark. (2021) tarafından toplam 2148 adet fıstık görüntüsü üzerinde yapılan ön işleme adımları (histogram

eşitleme, Otsu eşikleme yöntemi ile bölütleme) sonucunda her bir fıstık örneğinden 28 adet sayısal öznitelik çıkarılmıştır. Bu öznitelikler, literatürdeki benzer çalışmalardan farklı olarak daha kapsamlı bir öznitelik mühendisliği sürecinin ürünüdür. Ozkan ve ark. (2021), Singh ve ark. (2022) ve Uzer (2025) çalışmalarında 16 öznitelikli veri seti kullanılırken bu çalışmada 28 öznitelikli veri seti kullanılmaktadır. Kullanılan öznitelikler beş ana kategoride Çizelge 1'deki gibi gruplandırılabilir.

Çizelge 1. Antep fıstığı veri setinde kullanılan öznitelik kategorileri ve sayıları
Table 1. Feature categories and numbers used in the pistachio dataset

Öznitelik Kategorisi	Öznitelik Sayısı	Açıklama
Morfolojik ve Şekil Öznitelikleri	16	Alan, çevre, eksenler, eksantriklik, dolgunluk, şekil faktörleri vb.
Renk Öznitelikleri (Ortalama)	3	RGB kanallarının ortalama değerleri (Mean_RR, Mean_RG, Mean_RB)
Doku Öznitelikleri (Standart Sapma)	3	RGB kanallarının standart sapmaları (StdDev_RR, StdDev_RG, StdDev_RB)
Doku Öznitelikleri (Çarpıklık)	3	RGB kanallarının çarpıklık değerleri (Skew_RR, Skew_RG, Skew_RB)
Doku Öznitelikleri (Basıklık)	3	RGB kanallarının basıklık değerleri (Kurtosis_RR, Kurtosis_RG, Kurtosis_RB)

Veri setindeki sınıf dağılımı incelendiğinde, 1232 adet görüntünün Kırmızı sınıfına, 916 adet görüntünün ise Siirt sınıfına ait olduğu görülmektedir. Bu dağılım, gerçek dünyadaki üretim oranlarını yansıtmakta olup, sınıflar arasında hafif bir dengesizlik (%57,4-%42,6) bulunmaktadır. Dengesizliğin olası olumsuz etkilerini gidermek amacıyla çalışmada SMOTE kullanılmıştır. Chawla ve ark. (2002) tarafından geliştirilen SMOTE, k-NN arasında enterpolasyon yoluyla yeni azınlık sınıfı örnekleri üretmekte ve sınıf dağılımını dengelemektedir. SMOTE, tarım ve gıda işleme alanlarındaki dengesizlik sorunlarını ele alan çeşitli çalışmalarda başarıyla uygulanmıştır. SMOTE uygulamasının ardından dengesiz şarap kalitesi veri setinde RF sınıflandırıcısının hassasiyetinin 0,32'den 0,96'ya ve ROC eğrisi altında kalan alan (AUC) değerinin 0,88'den 0,99'a yükseldiği raporlanmıştır. Gıda kaynaklı patojen tahmin modellerine yönelik araştırmalar da SMOTE tabanlı yeniden örneklemenin model doğruluğunu anlamlı biçimde iyileştirdiğini ortaya koymuştur (Adegbenjo and Ngadi, 2024).

Veri seti, eğitim ve test olmak üzere ikiye ayrılmıştır. Literatürdeki çalışmalarla tutarlılık sağlamak amacıyla, temel modellerde %70 eğitim ve %30 test oranı kullanılmış; hiperparametre optimizasyonu sırasında ise eğitim seti üzerinde 5 katlı çapraz doğrulama uygulanmıştır. Tüm öznitelikler, her birinin eğitim verisi üzerindeki ortalaması çıkarılıp standart sapmasına bölünerek (z-puanı standardizasyonu) aynı ölçek seviyesine getirilmiştir. Böylece, sayısal değerleri doğal olarak büyük olan özniteliklerin sınıflandırma üzerindeki baskısı ortadan kaldırılmış ve tüm değişkenlerin modele eşit düzeyde katkıda bulunması sağlanmıştır.

Metasezgisel Algoritmalar

Bu çalışmada, LR, SVM ve XGBoost sınıflandırıcılarının hiperparametrelerini optimize etmek amacıyla altı farklı metasezgisel algoritma kullanılmıştır: PSO, Yapay Arı Kolonisi (ABC) Algoritması, Hızlı Uçuş Optimize Edici (SFO), Tardigrat Optimizasyon Algoritması (TOA), Bilby Optimizasyon Algoritması (BOA) ve Schrödinger Optimize Edici (SRA). Algoritmaların seçiminde, literatürde yaygın olarak kullanılan ve hiperparametre optimizasyonunda etkinliği kanıtlanmış klasik yöntemler (PSO ve ABC) ile yakın zamanda önerilmiş yeni nesil metasezgisel algoritmaların (SFO, TOA, BOA, SRA) karşılaştırmalı olarak değerlendirilmesi hedeflenmiştir. Bu sayede hem geleneksel hem de modern yaklaşımların aynı deneysel çerçevede performanslarının ortaya konması ve hangi algoritma türünün tarımsal sınıflandırma problemlerinde hiperparametre optimizasyonu için daha uygun olduğunun belirlenmesi amaçlanmıştır.

Problem Tanımı ve Uygunluk (Fitness) Fonksiyonu

Her bir algoritma, sınıflandırıcının doğruluk performansını maksimize eden hiperparametre kombinasyonunu aramak üzere popülasyon tabanlı bir arama süreci yürütmüştür. Optimizasyon sürecinin temel bileşenlerine bakıldığında bir sınıflandırıcının hiperparametre seti $\Theta = \{\theta_1, \theta_2, \dots, \theta_d\}$ ile gösterilsin. Her bir hiperparametre, sürekli veya kategorik bir değer aralığına sahiptir. Bu çalışmada optimize edilen hiperparametreler ve aralıkları Çizelge 2'de verilmiştir. LR ve SVM'deki C, düzenlileştirme parametresi olup modellerin karmaşıklığını cezalandırarak aşırı öğrenmeyi (overfitting) önlemektedir.

Çizelge 2. Sınıflandırıcılara ait optimize edilen hiperparametreler ve arama aralıkları
Table 2. Optimized hyperparameters and search ranges for classifiers

Sınıflandırıcı	Hiperparametre	Tipi	Aralık / Değerler
LR	C	Sürekli	[0,01-100]
	Çözücü	Kategorik	{'lbfgs', 'liblinear'}
SVM	C	Sürekli	[0,1-100]
	Gamma	Sürekli	[0,001-10]
	Kernel	Kategorik	{'rbf', 'poly'}
XGBoost	n_tahminci	Tamsayı	[50-200]
	maks_derinlik	Tamsayı	[3-10]
	Öğrenme oranı	Sürekli	[0,01-0,3]

Metasezgisel algoritmalar, sürekli değerler ürettikleri için her bir bireyin konum vektörü [0,1] aralığında normalize edilmiş değerlerden oluşur. Bu değerler, Çizelge 2'deki aralıklara doğrusal dönüşüm veya kategorik eşleme ile ilgili hiperparametre değerlerine çevrilir. Tamsayı parametreler (örn. n_tahminci) yuvarlama işlemine tabi tutulur. Amaç fonksiyonu, sınıflandırıcının 5 katlı çapraz doğrulama ile hesaplanan ortalama doğruluk (accuracy) değeridir. Metasezgisel algoritmalar minimizasyon problemi üzerinden tanımlandığından, uygunluk değeri $1 - accuracy$ olarak Denklem (1)'deki gibi alınmıştır.

$$F(\theta) = 1 - \frac{1}{K}\sum_{k=1}^{K} acc_k \quad (1)$$

Burada $K = 5$ olup, 5 katlı çapraz doğrulamadaki kat sayısını ifade etmektedir. acc_k ise k. katmandaki doğruluk oranıdır. Böylece en iyi hiperparametre seti, uygunluk değerini minimize eden birey olarak belirlenmiştir. Tüm algoritmalar için popülasyon büyüklüğü $N = 15$, maksimum iterasyon sayısı $T = 20$ olarak alınmıştır. Bu sayıların belirlenmesinde ön denemelerde daha yüksek değerlerin (örn. N=30, T=50) sınıflandırma doğruluğunda anlamlı bir iyileşme sağlamadığı, buna karşın hesaplama süresini önemli ölçüde artırdığı gözlemlenmiştir; bu nedenle hesaplama maliyetini sınırlamak amacıyla mevcut parametreler tercih edilmiştir. Her bir algoritma-sınıflandırıcı kombinasyonu için optimizasyon süreci bağımsız olarak çalıştırılmıştır. Kullanılan her bir metasezgisel algoritmanın temel işleyişi ve hiperparametre optimizasyonuna uyarlanması denklemlerle birlikte sıradaki bölümlerde sunulmaktadır.

PSO Algoritması Hiperparametre Optimizasyonu Uyarlaması

Kennedy ve Eberhart (1995) tarafından geliştirilen PSO, kuş sürülerinin sosyal davranışından esinlenen popülasyon tabanlı bir optimizasyon yöntemidir. Her bir parçacık, konum x_i ve hız v_i vektörlerine sahiptir. Konum, aday hiperparametre setini temsil eder. Parçacıklar, kişisel en iyi konumları (p_{best}) ve sürünün küresel en iyi konumunu (g_{best}) takip ederek konumlarını günceller. Hız ve konum güncelleme denklemleri Denklem (2) ve Denklem (3)'teki gibidir. Burada w, parçacığın bir önceki hızının ne kadarını koruyacağını belirleyen hız korunum katsayısıdır (bu çalışmada $w = 0{,}7$). c_1 ve c_2 bilişsel ve sosyal katsayılar ($c_1 = c_2 = 1{,}5$), $r_1, r_2 \sim U(0{,}1)$ ise rastgele sayılardır. Hiperparametre optimizasyonunda her bir parçacığın konum vektörü $[0{,}1]$ boyutunda olup, uygunluk fonksiyonu çapraz doğrulama doğruluğu üzerinden hesaplanmaktadır.

$$v_i(t+1) = w v_i(t) + c_1 r_1 (p_{\text{best},i} - x_i(t)) + c_2 r_2 (g_{\text{best}} - x_i(t)) \quad (2)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3)$$

ABC Algoritması Hiperparametre Optimizasyonu Uyarlaması

Karaboga (2005) tarafından önerilen ABC algoritması, bal arılarının yiyecek arama davranışını modellemektedir. Popülasyon üç tür arıdan oluşur: işçi arılar, gözlemci arılar ve kâşif arılar. İşçi arılar mevcut yiyecek kaynakları (çözümler) etrafında komşuluk araması yapar; gözlemci arılar, uygunluk değerine göre olasılıksal olarak kaynak seçer; kâşif arılar ise tükenen kaynakları yeniler. Bir işçi arının yeni bir konum üretmesi, Denklem (4) ile gösterilmektedir. Burada j rastgele seçilen bir boyut, $k \neq i$ rastgele bir birey, $\phi_{ij} \sim U(-1{,}1)$ ölçekleme faktörüdür. Üretilen v_i aday çözümünün uygunluk değeri hesaplanır ve açgözlü seçim ile mevcut konum güncellenir. Gözlemci arı aşamasında, bir kaynağın seçilme olasılığı Denklem (5)'te hesaplanmaktadır. Tükenme sayacı (limit) aşıldığında kâşif arı devreye girerek rastgele yeni bir konum üretir. ABC algoritması, hiperparametre uzayında keşif ve sömürü dengesini sağlamada etkilidir. ABC'de limit değeri $N \times D$ olarak alınmıştır.

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (4)$$

$$P_i = \frac{\text{uygunluk}_i}{\sum_{j=1}^{N} \text{uygunluk}_j} \quad (5)$$

SFO Algoritması Hiperparametre Optimizasyonu Uyarlaması

Kareem ve ark. (2025) tarafından geliştirilen SFO, kırlangıç kuşlarının adaptif uçuş dinamiklerinden esinlenmiştir. Algoritma üç modlu bir arama çerçevesi sunar: süzülme modu ile global keşif, hedef modu ile yönlendirilmiş sömürü ve mikro modu ile yerel iyileştirme. Her bir birey için mod seçimi rastgele yapılır. Süzülme modu, global keşifi temsil etmekte olup Denklem (6) ve Denklem (7)'de gösterildiği üzere Lévy uçuşu ile uzun adımlar atılır. Burada L, Lévy adım vektörü; $\alpha = 0{,}5$ ve $\beta = 0{,}5$ ölçekleme faktörleridir. I ise birim matrisi temsil etmektedir.

$$v_i^{t+1} = w v_i^t + \alpha \mathcal{N}(0, I) + \beta L \quad (6)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (7)$$

Denklem 8'deki hedef modu, sömürüyü temsil etmekte olup kişisel ve küresel en iyiye doğru yönlendirilmiş hareketleri tespit etmektedir. Burada ψ_1 ve ψ_2, ivme katsayılarını göstermekte olup literatüre paralel şekilde 1,5 olarak alınmıştır. Denklem 9'daki mikro modu, yerel iyileştirmeyi temsil etmekte olup küresel en iyi etrafında küçük pertürbasyon gerçekleştirir. Burada $\epsilon \sim \mathcal{N}(0 - 0{,}01)$ Gauss gürültüsüdür. Literatürle uyumlu olarak w değeri 0,7 olarak alınmıştır.

$$v_i^{t+1} = w v_i^t + \psi_1 r_1 (p_{\text{best}} - x_i^t) + \psi_2 r_2 (g_{\text{best}} - x_i^t) \quad (8)$$

$$v_i^{t+1} = w v_i^t + \psi_2 r_2 (g_{\text{best}} - x_i^t) + \epsilon \quad (9)$$

TOA Hiperparametre Optimizasyonu Uyarlaması

Yao ve ark. (2026) tarafından önerilen TOA, su ayılarının kriptobiyoz (yaşamsal faaliyetleri askıya alma) ve DNA onarım mekanizmalarından esinlenmiştir. Algoritma, popülasyonu sigmoid tabanlı uygunluk dönüşümü ile üç gruba ayırır: yüksek uygunluk (keşif), orta uygunluk (DNA onarımı) ve düşük uygunluk (t-dağılımı pertürbasyonu). Yüksek uygunluk grubu için Lévy uçuşu ile global arama Denklem (10)'da gösterilmektedir. Denklem (11) ve Denklem (12)'de gösterilen orta uygunluk grubu, hasar seviyesine bağlı olarak hasarlı

bireylerin onarılmasını ve çözüm kalitesinin iyileştirilmesini sağlamaktadır. Denklem (13)'te gösterilen düşük uygunluk grubunda t-dağılımı ile çeşitlilik artırılır. Yao ve ark. (2026) çalışması takip edilerek β_0=1,5, r_s=0,2 ve ν_{base}=0,05 olarak alınmıştır.

$$X_i(t+1) = X_i(t) + \omega \cdot (X_{\text{best}} - X_i(t)) + p_{\text{high}} \cdot \mathcal{N}(0,1) \quad (10)$$

$$\delta_i = \frac{f_i - f_{\text{best}}}{f_{\text{best}} + \epsilon}, r_i = \exp(-\delta_i) \quad (11)$$

$$M = A + (B - C) \cdot r_i(\text{HDR}), X_i(t+1) = X_i(t) + \omega \cdot (M - X_i(t)) \cdot r_i \cdot p_{\text{moderate}} \quad (12)$$

$$\text{disturbance} = \frac{\text{trnd}(\nu,1,D)}{\max(|\text{trnd}(\nu,1,D)|)}, X_i(t+1) = X_i(t) + (\bar{X}_{\text{low}} - X_i(t)) \cdot \text{disturbance} \cdot p_{\text{low}} \quad (13)$$

BOA Hiperparametre Optimizasyonu Uyarlaması

Montazeri ve ark. (2026) tarafından önerilen BOA, keseli tavşan (bilbi) hayvanının gece beslenmesi, yuva değiştirme ve spiral kazma davranışlarından esinlenen üç fazlı bir algoritmadır. Her bir birey, üç farklı strateji ile konumunu günceller. Birinci faz olan gece beslenmesinde (global keşif), rastgele bir konum (X_R) ve iterasyonla artan koku alma duyarlılığı ($\eta = 2t/T$) kullanılarak Denklem (14)'teki gibi yeni konum hesaplanır. İkinci faz olan yuva değiştirmede (yönlendirilmiş keşif), daha iyi uygunluğa sahip bireyler arasından rastgele bir yuva ($Nest_i$) seçilir ve Denklem (15)'deki gibi konum güncellenir. Üçüncü faz olan spiral kazmada (yerel sömürü) ise Denklem (16)'daki gibi küçük rastgele pertürbasyon uygulanarak konum iyileştirilir. I_1, I_2, I_3 ve I_4 rastgele tamsayılar ($\in \{1,2\}$) olarak seçilmiştir.

$$X_i^{P1} = X_i + r_1 \cdot (X_R - I_1 \cdot X_i) + \eta \cdot r_2 \quad (14)$$

$$X_i^{P2} = X_i + 2 \cdot I_3 \cdot r_3 \cdot (Nest_i - I_4 \cdot X_i) \quad (15)$$

$$X_i^{P3} = X_i + \Delta, \Delta \sim U(-1,1) \cdot \frac{ub - lb}{10} \quad (16)$$

SRA Hiperparametre Optimizasyonu Uyarlaması

Hussein ve ark. (2025) tarafından geliştirilen SRA, Schrödinger dalga denklemi ve dalga-parçacık ikiliğinden ilham almaktadır. Algoritma, dalga benzeri (keşif) ve parçacık benzeri (sömürü) güncellemeler arasında geçiş yapar. Dalga fonksiyonu $\psi(x) = \sin(x)$ olarak seçilmiştir. Dalga benzeri güncelleme (keşif) Denklem 17'deki gibi yapılmaktadır. Parçacık benzeri güncelleme (sömürü), Denklem (18)'deki gibi Newton hareket yasasına dayanmaktadır. Burada Hussein ve ark. (2025) çalışması takip edilerek k=1 ve h=0,1 olarak alınmıştır.

$$X_{i+1} = X_{\text{best}} + \frac{\text{rand} \cdot z_c + h(\psi(X_{\text{best}}) - \psi(X_{\text{worst}})) + p[i](\psi(X_{\text{rand1}}) - \psi(X_i) + \psi(X_{\text{rand2}}))}{\psi(X_i) + \epsilon} \quad (17)$$

$$X_{i+1} = k \cdot \text{rand} + 2X_i - X_{i-1} \quad (18)$$

Hiperparametre Optimizasyon Sürecinin Ortak Adımları

Tüm metasezgisel algoritmalar için aşağıdaki ortak adımlar izlenmiştir:

1. Popülasyon başlatma: Her bireyin konum vektörü $[0,1]^d$ aralığında rastgele üretilir.
2. Uygunluk değerlendirme: Her bireyin konumu, ilgili sınıflandırıcının hiperparametrelerine dönüştürülür. 5 katlı çapraz doğrulama ile ortalama doğruluk hesaplanır ve $fitness = 1 -$ accuracy olarak atanır.
3. Konum güncelleme: Algoritmaya özgü kurallarla yeni konumlar üretilir. Geçerlilik sınırları $[0,1]$ aralığı ile kırpılır.
4. Elitizm: Her iterasyon sonunda küresel en iyi çözüm korunur.
5. Durma kriteri: Maksimum iterasyon sayısına ($T = 20$) ulaşıldığında optimizasyon sonlandırılır.

Optimizasyon tamamlandıktan sonra, elde edilen en iyi konum vektörü ilgili hiperparametrelere dönüştürülerek nihai model eğitilmiş ve bağımsız test seti üzerinde değerlendirilmiştir. Bu süreçte doğruluk, F1-skor ve AUC metrikleri hesaplanmış, ayrıca her bir optimizasyonun çalışma süresi kaydedilmiştir. Tüm deneysel çalışmalar, Google Colaboratory (Colab) platformunda Python programlama dili kullanılarak gerçekleştirilmiştir. Algoritmalar rassal veriler üzerinde çalıştığı için her metasezgisel optimizasyon-sınıflandırıcı kombinasyonu için 30 iterasyon gerçekleştirilmiş ve ortalama değerler ile standart sapma değerleri kullanılmıştır.

Bulgular ve Tartışma

Bu bölümde, Antep fıstığı türlerinin (Kırmızı ve Siirt) sınıflandırılması için gerçekleştirilen deneysel çalışmaların sonuçları sunulmaktadır. Öncelikle, hiperparametre optimizasyonu uygulanmadan varsayılan parametrelerle eğitilen modellerin performansı verilmiş, ardından altı farklı metasezgisel algoritma ile optimize edilen LR, SVM ve XGBoost sınıflandırıcılarının sonuçları karşılaştırmalı olarak sunulmuştur. Yöntem bölümünde verilen hiperparametre değerleri, literatürdeki çalışmalardan alınmış olup bu çalışmada farklı hiperparametre setleri denenmeyerek orijinal çalışmalardaki değerlere sadık kalınmıştır.

Hiperparametre Optimizasyonu Olmayan Modellerin Performansı

Çizelge 3, herhangi bir hiperparametre optimizasyonu uygulanmadan, varsayılan parametre değerleriyle eğitilen LR, SVM ve XGBoost modellerinin test performansını göstermektedir. Varsayılan parametreler kullanıldığında en yüksek doğruluk SVM ile (%93,02) elde edilmiştir. LR (%92,56) ve XGBoost (%91,94) da kabul edilebilir düzeyde başarı göstermiştir. Tüm modellerin AUC değerleri 0,975 ile 0,980 arasında değişmekte olup yüksek ayırt edicilik sergilemektedir. Hesaplama süresi açısından LR (0,03 saniye) en hızlı model olurken, XGBoost (2,03 saniye) diğerlerine göre daha uzun sürmüştür.

LR için Metasezgisel Optimizasyon Sonuçları

Çizelge 4, LR sınıflandırıcısının altı farklı metasezgisel algoritma ile optimize edilmesi sonucunda elde edilen test performansını göstermektedir.

Çizelge 3. Hiperparametre optimizasyonu uygulanmayan varsayılan modellerin test performansı
Table 3. Test performance of default models without hyperparameter optimization

Sınıflandırıcı	Doğruluk	F1-Skor	AUC	Süre (sn)
LR	0,9256	0,9258	0,9799	0,03
SVM	0,9302	0,9304	0,9775	0,62
XGBoost	0,9194	0,9196	0,9760	2,03

Çizelge 4. LR için metasezgisel optimizasyon sonuçları
Table 4. Meta-heuristic optimization results for Logistic Regression

Algoritma	Doğruluk (Ort)	Doğruluk (Std. Sapma)	F1-Skor	AUC	Süre (sn)
PSO	0,9240	0,0013	0,9243	0,9793	56,29
ABC	0,9225	0,0011	0,9227	0,9800	60,30
SFO	0,9240	0,0010	0,9243	0,9799	29,25
TOA	0,9256	0,0009	0,9258	0,9798	49,29
BOA	0,9240	0,0015	0,9243	0,9793	152,71
SRA	0,9240	0,0009	0,9243	0,9796	33,16

Tüm algoritmalar benzer doğruluk değerleri (%92,20–92,56) üretmiştir. Bu durum, LR'nin hiperparametrelere karşı nispeten daha az duyarlı olduğunu göstermektedir. Standart sapma değerlerinin 0,0009 ile 0,0015 arasında değişmesi, tüm algoritmaların LR üzerinde oldukça tutarlı ve kararlı performans sergilediğini teyit etmektedir. En yüksek doğruluk TOA algoritması ile (%92,56) elde edilirken, en hızlı optimizasyon SFO algoritması ile 29,25 saniyede tamamlanmıştır. BOA algoritması ise en uzun süreyi (152,71 sn) gerektirmiştir.

SVM için Metasezgisel Optimizasyon Sonuçları

Çizelge 5, SVM sınıflandırıcısının altı farklı metasezgisel algoritma ile optimize edilmesi sonucunda elde edilen test performansını göstermektedir. SVM sınıflandırıcısında algoritmalar arasında belirgin performans farkları gözlenmiştir. En yüksek doğruluk BOA + SVM kombinasyonu ile (%93,64) elde edilmiştir. Bu kombinasyon aynı zamanda 0,9366 F1-skor ve 0,9804 AUC değerleriyle de yüksek performans sergilemiştir. Ancak bu başarının elde edilmesi için yaklaşık 2150 saniye (~36 dakika) optimizasyon süresi gerektiği belirtilmelidir. Standart sapma değerleri incelendiğinde, PSO algoritması hem en düşük doğruluğu (%88,68) hem de en yüksek standart sapmayı (0,0172) sergileyerek en kararsız performansı göstermiştir. Buna karşılık BOA ve SRA, sırasıyla 0,0018 ve 0,0023 standart sapma değerleri ile en tutarlı sonuçları üretmiştir. PSO ve ABC algoritmaları varsayılan SVM modelinin gerisinde kalırken, TOA ve SRA varsayılan modele yakın veya daha iyi sonuçlar elde etmiştir.

XGBoost için Metasezgisel Optimizasyon Sonuçları

Çizelge 6, XGBoost sınıflandırıcısının altı farklı metasezgisel algoritma ile optimize edilmesi sonucunda elde edilen test performansını göstermektedir. XGBoost sınıflandırıcısında PSO ve SRA aynı doğruluk değerine ulaşmıştır. SRA + XGBoost kombinasyonu AUC bakımından en yüksek değere (0,9806) sahip olup, PSO + XGBoost'a göre daha düşük sürede (704,04 saniye) tamamlanmıştır. Standart sapma açısından SRA, 0,0004 ile en düşük değeri vererek en kararlı performansı sergilerken, PSO da 0,0006 ile oldukça tutarlı sonuçlar üretmiştir. BOA ve ABC ise sırasıyla 0,0027 ve 0,0029 standart sapma değerleri ile nispeten daha değişken performans göstermiştir.

Çizelge 5. SVM için metasezgisel optimizasyon sonuçları
Table 5. Meta-heuristic optimization results for SVM

Algoritma	Doğruluk (Ort)	Doğruluk (Std. Sapma)	F1-Skor	AUC	Süre (sn)
PSO	0,8868	0,0172	0,8872	0,9401	937,77
ABC	0,9116	0,0039	0,9115	0,9658	1010,50
SFO	0,9147	0,0034	0,9146	0,9664	720,94
TOA	0,9271	0,0030	0,9274	0,9814	740,24
BOA	0,9364	0,0018	0,9366	0,9804	2150,17
SRA	0,9333	0,0023	0,9335	0,9819	799,20

Çizelge 6. XGBoost için metasezgisel optimizasyon sonuçları
Table 6. Meta-heuristic optimization results for XGBoost

Algoritma	Doğruluk (Ort)	Doğruluk (Std. Sapma)	F1-Skor	AUC	Süre (sn)
PSO	0,9349	0,0006	0,9350	0,9794	454,85
ABC	0,9271	0,0029	0,9272	0,9797	732,55
SFO	0,9333	0,0023	0,9334	0,9805	584,19
TOA	0,9256	0,0014	0,9257	0,9782	580,97
BOA	0,9302	0,0027	0,9303	0,9801	1684,92
SRA	0,9349	0,0004	0,9349	0,9806	704,04

BOA algoritması 1684,92 saniye ile en uzun optimizasyon süresini gerektirirken, doğruluk bakımından varsayılan model seviyesinde kalmıştır.

Genel Performans Değerlendirmesi ve Görsel Karşılaştırma

Çizelge 7, tüm kombinasyonlar arasında en yüksek doğruluk, en yüksek AUC ve en hızlı optimizasyon süresi bakımından en iyi modelleri özetlemektedir. En yüksek test doğruluğuna BOA + SVM kombinasyonu ile ulaşılmıştır (%93,64). En yüksek ayırt edicilik gücü (AUC) SRA + XGBoost modelinde (0,9806) gözlenmiştir. En hızlı optimizasyon süresi ise SFO + LR kombinasyonunda (29,25 saniye) elde edilmiştir. Varsayılan modellerle karşılaştırıldığında, metasezgisel optimizasyon SVM ve XGBoost sınıflandırıcılarında performans iyileşmesi sağlarken, LR'de sınırlı iyileşme gözlenmiştir. Doğruluk ile optimizasyon süresi arasındaki ödünleşimi daha net ortaya koymak amacıyla Şekil 1'de seçili model kombinasyonlarının test doğruluğu (mavi çubuklar) ve optimizasyon süresi (kırmızı noktalar, logaritmik ölçek) birlikte gösterilmiştir. Şekil 1 incelendiğinde, varsayılan LR modeli 0,03 saniye gibi ihmal edilebilir bir sürede %92,56 doğruluk sunarken, SFO ile optimize edilmiş LR modeli 29 saniyede benzer bir doğruluğa (%92,40) ulaşmıştır. BOA ile optimize edilmiş SVM modeli en yüksek doğruluğa (%93,64) sahip olmasına rağmen yaklaşık 2150 saniyelik bir optimizasyon süresi gerektirmektedir. SRA ile optimize edilmiş XGBoost modeli ise 704 saniyede %93,49 doğruluk ve en yüksek AUC değerini (0,9806) sağlayarak doğruluk-süre dengesi açısından en uygun seçenek olarak öne çıkmaktadır. PSO ile optimize edilmiş XGBoost modeli de aynı doğruluğa 454 saniyede ulaşmış, fakat AUC değeri (0,9794) SRA+XGBoost'unkine göre daha düşük kalmıştır. Varsayılan SVM modeli ise 0,62 saniyede %93,02 doğruluk ile hızlı ve kabul edilebilir bir alternatif olarak görülmektedir.

Sonuçlar ve Tartışma

Tarım sektörü, küresel nüfus artışı ve iklim değişikliğinin baskıları altında üretim verimliliğini artırma, israfı azaltma ve gıda güvenliğini sağlama gibi zorlu hedeflerle karşı karşıyadır. Bu bağlamda, tarımsal ürünlerin hızlı, doğru ve düşük maliyetli yöntemlerle tespiti ve sınıflandırılması; hasat sonrası işleme, kalite kontrol, pazarlama ve tedarik zinciri yönetimi açısından kritik öneme sahiptir. Geleneksel manuel ayırma yöntemleri öznel, zaman alıcı ve yüksek iş gücü gerektiren süreçler olup, özellikle yüksek katma değerli ürünlerde (kuruyemişler, meyveler, tahıllar) otomatik sınıflandırma sistemlerine olan ihtiyacı artırmaktadır.

Çizelge 7. En iyi performans gösteren modellerin özeti
Table 7. Summary of the best-performing models

Kriter	Yöntem	Doğruluk	F1-Skor	AUC	Süre (sn)
En yüksek doğruluk	BOA + SVM	0,9364	0,9366	0,9804	2150,17
En yüksek AUC	SRA + XGBoost	0,9349	0,9349	0,9806	704,04
En hızlı optimizasyon	SFO + LR	0,9240	0,9243	0,9796	29,25
En hızlı genel model	Varsayılan LR	0,9256	0,9258	0,9799	0,03

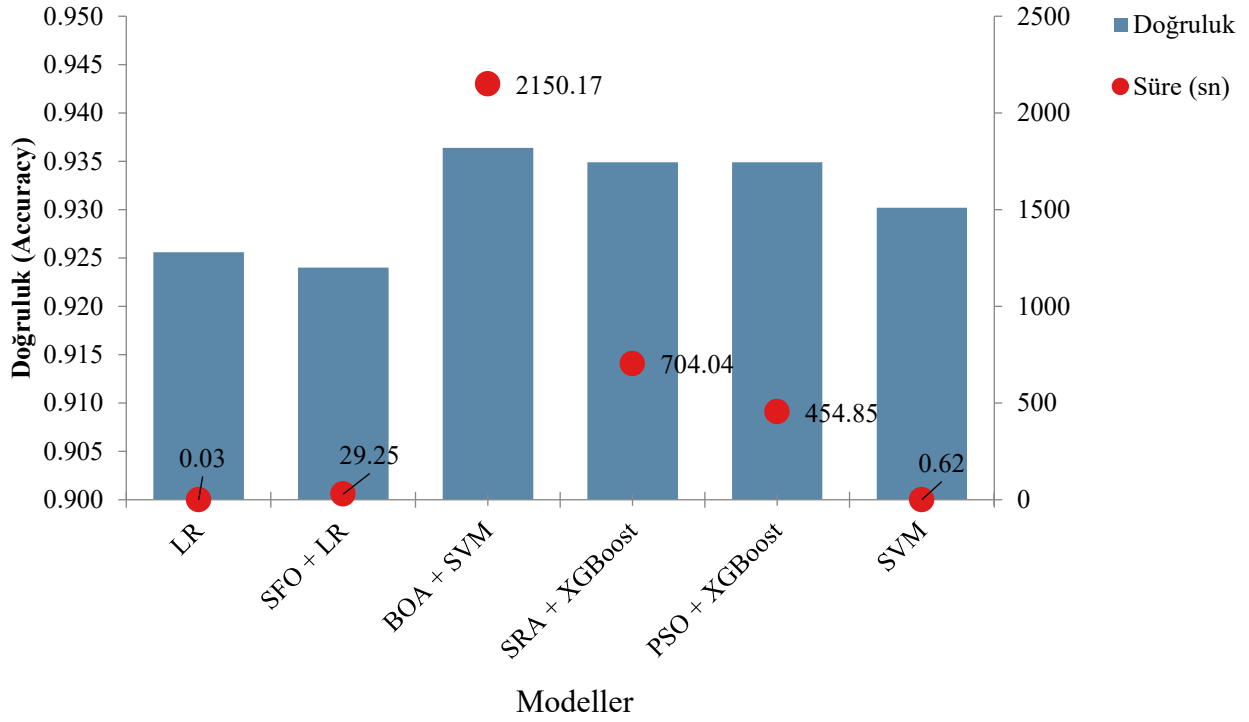

Şekil 1. En iyi modellerin doğruluk ve optimizasyon süresi karşılaştırması
Figure 1. Comparison of accuracy and optimization time of the best models

Çalışmanın Özeti ve Temel Bulgular

Bu çalışma, Antep fıstığının iki ticari türü olan Kırmızı ve Siirt çeşitlerinin, metasezgisel optimizasyon tabanlı ML yöntemleriyle otomatik olarak ayrıştırılmasına yönelik kapsamlı bir karşılaştırmalı analiz sunmaktadır. Çalışmada 28 morfolojik, renk ve doku özniteliğinden oluşan bir veri seti (2148 örnek) kullanılarak LR, SVM ve XGBoost sınıflandırıcılarının hiperparametreleri altı farklı metasezgisel algoritma (PSO, ABC, SFO, TOA, BOA, SRA) ile optimize edilmiştir. SMOTE tekniği ile sınıf dengesizliği giderilmiş, modeller 5 katlı çapraz doğrulama ile değerlendirilmiş ve bağımsız test setinde doğruluk, F1-skor ve AUC metrikleri hesaplanmıştır. Elde edilen bulgular şu şekilde özetlenebilir:

- Varsayılan (optimizasyon yapılmamış) modeller arasında en yüksek doğruluk SVM ile (%93,02) elde edilirken, LR (%92,56) ve XGBoost (%91,94) izlemiştir. Varsayılan LR modeli 0,03 saniye ile en hızlı model olmuştur.
- LR için tüm metasezgisel algoritmalar benzer doğruluklar (%92,20–92,56) üretmiş; en hızlı optimizasyon SFO (29,25 sn) ile gerçekleşmiştir. Bu durum, LR'nin hiperparametrelere karşı düşük duyarlılığını göstermektedir.
- SVM sınıflandırıcısında en yüksek doğruluk BOA algoritması ile (%93,64) elde edilmiştir. BOA+SVM kombinasyonu aynı zamanda en yüksek F1-skor (0,9366) değerini vermiş, ancak bu başarı yaklaşık 2150 saniyelik bir optimizasyon süresi gerektirmiştir. SRA ile optimize edilen SVM ise %93,33 doğruluk ve 0,9819 AUC ile yüksek ayırt edicilik sergilemiştir.
- XGBoost sınıflandırıcısında PSO ve SRA algoritmaları aynı doğruluk değerine (%93,49) ulaşmıştır. SRA+XGBoost kombinasyonu en yüksek AUC (0,9806) değerine sahip olup, PSO+XGBoost'a göre daha düşük sürede (704 sn) tamamlanmıştır.
- Genel olarak, metasezgisel optimizasyon SVM ve XGBoost performansında varsayılan modellere kıyasla anlamlı iyileşmeler sağlamış (SVM'de %0,6, XGBoost'ta %1,55), ancak bu iyileşmeler yüksek hesaplama maliyeti ile elde edilmiştir. LR'de ise iyileşme sınırlı kalmıştır.

Bu sonuçlar, özellikle BOA ve SRA gibi yeni nesil metasezgisel algoritmaların, tarımsal ürün sınıflandırma problemlerinde rekabetçi performans sunduğunu ve doğruluk ile hesaplama maliyeti arasında tercih yapılması gerektiğini ortaya koymaktadır.

Elde edilen en yüksek doğruluk (%93,64) literatürdeki bazı çalışmalara kıyasla daha düşük kalmıştır. Örneğin, aynı veri seti üzerinde Ozkan ve ark. (2021) %94,2 doğruluk elde ederken, Singh ve ark. (2022) ve Uzer (2025) sırasıyla %98,84 ve %99,63 gibi çok daha yüksek başarılar raporlamıştır. Bu farklılığın başlıca nedenleri arasında, iki çalışmanın derin öğrenme mimarilerini (CNN) kullanması ve bu modellerin ham görüntülerden otomatik olarak zengin öznitelik temsilleri öğrenebilmesi yer almaktadır. Ayrıca bu çalışmada, el ile çıkarılan 28 öznitelik ile sınırlı kalınması, hesaplama maliyetini kontrol altında tutmak amacıyla popülasyon büyüklüğü ve iterasyon sayısının nispeten düşük tutulması da performansı etkileyen faktörler arasındadır. Bununla birlikte çalışmanın temel katkısı, derin öğrenme ile rekabet etmekten ziyade, klasik makine öğrenmesi yöntemlerinde metasezgisel hiperparametre optimizasyonunun etkinliğini ve özellikle BOA, SRA gibi yeni nesil algoritmaların bu bağlamda sunduğu potansiyeli ortaya koymaktır.

Politika Çıkarımları

Bu çalışmanın bulguları, tarımsal ürün sınıflandırması ve kalite kontrolü konusunda politika yapıcılar, tarım teknolojileri geliştiricileri ve sektör paydaşları için çeşitli çıkarımlar sunmaktadır:

- Dijital Tarım Dönüşümüne Destek: Metasezgisel optimizasyon tabanlı sınıflandırma sistemleri, küçük ve orta ölçekli işletmelerin düşük maliyetli donanımlarla yüksek doğrulukta otomatik ayıklama yapmasını mümkün kılmaktadır. Politikalar, bu tür yapay zekâ destekli sistemlerin yaygınlaştırılmasını teşvik edecek hibe, düşük faizli kredi ve vergi indirimi gibi mekanizmaları içermelidir.
- Eğitim ve Kapasite Geliştirme: Çiftçiler ve işleme tesisi çalışanlarına, bu sistemlerin kurulumu, kullanımı ve temel bakımı konusunda eğitim programları düzenlenmelidir. Özellikle BOA ve SRA gibi yeni algoritmaların endüstriyel uygulamalara entegrasyonu için teknik personel yetiştirilmesi gerekmektedir.
- Ar-Ge ve Yenilik Teşvikleri: Üniversiteler ve araştırma enstitüleri, tarımsal sınıflandırma için daha hızlı, daha düşük maliyetli ve yorumlanabilir modeller geliştirmeye teşvik edilmelidir. Bu çalışmada olduğu gibi, varsayılan modeller ile optimize edilmiş modeller arasındaki doğruluk-süre ödünleşimini dikkate alan hibrit yaklaşımların desteklenmesi faydalı olacaktır.
- Veri Altyapısı ve Standardizasyon: Farklı bölgelerde yetiştirilen tarımsal ürünlere ait görüntü ve öznitelik veri setlerinin oluşturulması ve açık erişime sunulması, bu tür modellerin genellenebilirliğini artıracaktır. Politikalar, ulusal düzeyde standart veri toplama protokollerinin oluşturulmasını teşvik etmelidir.
- Sürdürülebilirlik ve Gıda İsrafının Azaltılması: Otomatik sınıflandırma sistemleri, ürünlerin doğru şekilde ayrılması sayesinde pazarlama sürecinde israfı azaltır ve yüksek kaliteli ürünlerin doğru pazarlara ulaşmasını sağlar. Bu durum, gıda güvenliği ve sürdürülebilir üretim hedefleriyle doğrudan uyumludur.

Sınırlılıklar ve Gelecek Çalışmalar

Bu çalışma Antep fıstığı türlerinin metasezgisel optimizasyon tabanlı ML yöntemleriyle sınıflandırılmasında önemli bulgular sunmakla birlikte, bazı sınırlılıklara sahiptir. Öncelikle, kullanılan veri seti yalnızca iki türü (Kırmızı ve Siirt) içermekte olup, diğer Antep fıstığı çeşitleri (Halebi, Ohadi vb.) veya farklı coğrafi bölgelerden toplanmış örnekleri kapsamamaktadır. Bu durum, geliştirilen modellerin genellenebilirliğini sınırlamaktadır. Ayrıca, yüksek doğruluk sağlayan bazı kombinasyonlar (örneğin BOA+SVM) yaklaşık 2150 saniye gibi endüstriyel gerçek zamanlı uygulamalar için pratik olmayan optimizasyon süreleri gerektirmektedir. Metasezgisel algoritmaların performansı, popülasyon

büyüklüğü ve iterasyon sayısı gibi parametrelere duyarlı olup, bu çalışmada sabit parametreler kullanılmıştır; farklı problemler için bu parametrelerin yeniden optimize edilmesi gerekebilir. Son olarak, çalışma belirli bir donanım yapılandırmasında gerçekleştirilmiş olup, farklı işlemci ve bellek özelliklerinde süreler değişkenlik gösterebilir.

Gelecek çalışmalarda daha fazla Antep fıstığı türü, farklı olgunluk seviyeleri ve hasat yıllarını içeren kapsamlı bir veri seti oluşturulması önerilmektedir. Ayrıca, farklı coğrafi bölgelere ait örneklerle modellerin genellenebilirliği test edilmelidir. Derin öğrenme mimarileri (CNN, VGG16, ResNet gibi) ile metasezgisel optimizasyonun birlikte kullanıldığı hibrit yaklaşımlar geliştirilerek ham görüntüler üzerinde doğrudan sınıflandırma yapılması sağlanabilir. BOA, SRA ve PSO gibi algoritmaların güçlü yönlerini birleştiren hibrit metasezgisel yöntemler tasarlanarak hem doğruluk hem de yakınsama hızı iyileştirilebilir. Geliştirilen modellerin düşük güçlü gömülü sistemler (Raspberry Pi, Jetson Nano vb.) üzerinde çalışacak şekilde optimize edilmesi ve mobil cihazlara entegre edilmesi, saha uygulamaları için büyük önem taşımaktadır. SHAP ve LIME gibi açıklanabilir yapay zekâ yöntemleriyle modellerin karar mekanizmalarının detaylı analizi yapılarak, çiftçi ve işletme yöneticileri için yorumlanabilir sonuçlar üretilmelidir. Bu iyileştirmeler, önerilen yaklaşımın tarımsal ürün sınıflandırma sistemlerinde daha yaygın ve etkin bir şekilde kullanılmasına olanak tanıyacaktır.

Beyanlar

Etik Onay

Bu çalışma, insan katılımcı veya hayvan deneyi içermemekte olup etik kurul onayı gerektirmemektedir.

Yazar Katkı Beyanı

Bu makalenin tüm aşamaları (çalışmanın tasarımı, veri toplama ve analizi, yazım ve gözden geçirme) tek bir yazar tarafından gerçekleştirilmiştir.

Çıkar Çatışması Beyanı

Yazar, bu çalışma ile ilgili herhangi bir çıkar çatışması bulunmadığını beyan etmektedir.

Finansman Beyanı

Bu çalışma için herhangi bir kurum/kuruluştan dış finansal destek alınmamıştır.

Kaynaklar

Adegbenjo, A. O., & Ngadi, M. O. (2024). Handling the imbalanced problem in agri-food data analysis. Foods, 13(20), 3300. https://doi.org/10.3390/foods13203300

Aktaş, H. (2022). Antep fıstığının derin öğrenme ile dış kabuk rengine göre sınıflandırılması. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 11(3), 461-466. https://doi.org/10.28948/ngumuh.1064522

Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. Journal of machine learning research, 13(2).

Blasco, J., Aleixos, N., & Molto, E. (2007). Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. Journal of Food engineering, 81(3), 535-543. https://doi.org/10.1016/j.jfoodeng.2006.12.007

Bülbül, H., Güler, E., & Yavuz, B. Ç. (2026). Machine Learning-Based Dual Agricultural Decision Support System: An Integrated Approach for Crop and Fertilizer Recommendations. Turkish Journal of Agriculture-Food Science and Technology, 14(1), 262-273. https://doi.org/10.24925/turjaf.v14i1.262-273.8336

Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. Journal of Artificial Intelligence Research, 16, 321–357. https://doi.org/10.1613/jair.953

Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning, 20(3), 273-297. https://doi.org/10.1023/a:1022627411411

Dreher, M. L. (2012). Pistachio nuts: composition and potential health benefits. Nutrition reviews, 70(4), 234-240. https://doi.org/10.1111/j.1753-4887.2011.00467.x

Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785-794).

Falkner, S., Klein, A., & Hutter, F. (2018). BOHB: Robust and efficient hyperparameter optimization at scale. In International conference on machine learning (pp. 1437-1446). PMLR.

FAO (2023, Nisan 23). FAOSTAT: Crops and Livestock Products. https://www.fao.org/faostat/en/ - data/QCL

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. Computers and electronics in agriculture, 145, 311-318. https://doi.org/10.1016/j.compag.2018.01.009

Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. International Journal of remote sensing, 23(4), 725-749. https://doi.org/10.1080/01431160110040323

Hussein, N. K., Qaraad, M., El Najjar, A. M., Farag, M. A., Elhosseini, M. A., Mirjalili, S., & Guinovart, D. (2025). Schrödinger optimizer: A quantum duality-driven metaheuristic for stochastic optimization and engineering challenges. Knowledge-Based Systems, 328,114273. https://doi.org/10.1016/j.knosys.2025.114273

Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization (Technical Report TR06). Erciyes University.

Kareem, A. A., Abid, A. J., Hammood, D. A., Yaqoob, S. J., Husein, A., & Bereznychenko, V. (2025). Swift Flight Optimizer: a novel bio-inspired optimization algorithm based on swift bird behavior. Scientific Reports, 15(1), 41597.https://doi.org/10.1038/s41598-025-25490-7

Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In Proceedings of ICNN'95-international conference on neural networks (Vol. 4, pp. 1942-1948). ieee. https://doi.org/10.1109/icnn.1995.488968

Kumar, S. S., Sigappi, A. N., Thomas, G. A. S., Robinson, Y. H., & Raja, S. P. (2023). Classification and Analysis of Pistachio Species Through Neural Embedding-Based Feature Extraction and Small-Scale Machine Learning Techniques. International Journal of Image and Graphics, 24(5), 2450032.https://doi.org/10.1142/s0219467824500323

Larochelle, H., Erhan, D., Courville, A., Bergstra, J., & Bengio, Y. (2007). An empirical evaluation of deep architectures on problems with many factors of variation. In Proceedings of the 24th international conference on Machine learning (pp. 473-480). https://doi.org/10.1145/1273496.1273556

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. nature, 521(7553), 436-444. https://doi.org/10.1038/nature14539

Leemans, V., Magein, H., & Destain, M. F. (2002). AE—automation and emerging technologies: on-line fruit grading according to their external quality using machine vision. Biosystems engineering, 83(4), 397-404. https://doi.org/10.1006/bioe.2002.0131

Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: a review. Sensors (Switzerland) 18 (8): 1–29. https://doi.org/10.3390/s18082674

Lima Marinho, T., do Nascimento, D. C., & Pimentel, B. A. (2024). Optimization on selecting XGBoost hyperparameters using meta-learning. Expert Systems, 41(9), e13611. https://doi.org/10.1111/exsy.13611

Mahdavi-Jafari, S., Salehinejad, H., & Talebi, S. (2008). A pistachio nuts classification technique: An ann based signal processing scheme. In 2008 International Conference on Computational Intelligence for Modelling Control & Automation (pp. 447-451). IEEE. https://doi.org/10.1109/cimca.2008.150

Mehdary, A., Chehri, A., Jakimi, A., & Saadane, R. (2024). Hyperparameter optimization with genetic algorithms and XGBoost: a step forward in smart grid fraud detection. sensors, 24(4), 1230.https://doi.org/10.3390/s24041230

Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. Frontiers in plant science, 7, 1419. https://doi.org/10.3389/fpls.2016.01419

Montazeri, Z., Dehghani, M., Smerat, A., Ismoilov, M., Zitar, R. A., Humod, A. T., & Eguchi, K. (2026). Bilby Optimization Algorithm (BOA): A Novel Bio-inspired Metaheuristic Algorithm for Solving Optimization Problems. International Journal of Intelligent Engineering and Systems, 19(4), 880-898. https://doi.org/10.22266/ijies2026.0430.50

Nandi, C. S., Tudu, B., & Koley, C. (2013). Machine vision based techniques for automatic mango fruit sorting and grading based on maturity level and size. In Sensing technology: current status and future trends II (pp. 27-46). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-319-02315-1_2

Omid, M., Firouz, M. S., Nouri-Ahmadabadi, H., & Mohtasebi, S. S. (2017). Classification of peeled pistachio kernels using computer vision and color features. Engineering in agriculture, environment and food, 10(4), 259-265. https://doi.org/10.1016/j.eaef.2017.04.002

Ozkan, I. A., Koklu, M., & Saracoglu, R. (2021). Classification of Pistachio Species Using Improved k-NN Classifier. Progress in Nutrition, 23(2), e2021044. https://doi.org/10.23751/pn.v23i2.9686

Probst, P., Boulesteix, A. L., & Bischl, B. (2019). Tunability: Importance of hyperparameters of machine learning algorithms. Journal of Machine Learning Research, 20(53), 1-32.

Qanith, M., & Khilar, R. (2025). Improving accuracy for recommending the appropriate crop using random forest in comparison with logistic regression. AIP Conference Proceedings, 3267(1), 020270. https://doi.org/10.1063/5.0265122

Raihen, M. N., & Akter, S. (2023). Prediction modeling using deep learning for the classification of grape-type dried fruits. International Journal of Mathematics and Computer in Engineering, 2(1), 1-12. https://doi.org/10.2478/ijmce-2024-0001

Rizkallah, L. W. (2025). Optimizing SVM hyperparameters for satellite imagery classification using metaheuristic and statistical techniques. International Journal of Data Science and Analytics, 20(5), 4945-4962.https://doi.org/10.1007/s41060-025-00762-7

Vapnik, V. (2013). The nature of statistical learning theory. Springer science & business media. https://doi.org/10.1007/978-1-4757-3264-1

Saranwong, S., Sornsrivichai, J., & Kawano, S. (2004). Prediction of ripe-stage eating quality of mango fruit from its harvest quality measured nondestructively by near infrared spectroscopy. Postharvest biology and technology, 31(2), 137-145. https://doi.org/10.1016/j.postharvbio.2003.08.007

Şimşek, F. F. (2025). Comparison of agricultural crop type classifications with different machine learning algorithms (RF-SVM-ANN-XGBoost) by generating ground truth data from farmer declaration parcels. International Journal of Engineering and Geosciences, 10(2), 207-220. https://doi.org/10.26833/ijeg.1552141

Singh, D., Taspinar, Y. S., Kursun, R., Cinar, I., Koklu, M., Ozkan, I. A., & Lee, H. N. (2022). Classification and analysis of pistachio species with pre-trained deep learning models. Electronics, 11(7), 981. https://doi.org/10.3390/electronics11070981

Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. Advances in neural information processing systems, 25.

Sonmez, M. E., Sabanci, K., & Aydin, N. (2024). Convolutional neural network-support vector machine-based approach for identification of wheat hybrids. European Food Research and Technology, 250(5), 1353-1362. https://doi.org/10.1007/s00217-024-04473-4

Turkay, Y., & Tamay, Z. S. (2024). Pistachio classification based on acoustic systems and machine learning. Elektronika Ir Elektrotechnika, 30(5), 4-13. https://doi.org/10.5755/j02.eie.38221

Uzer, M. S. (2025). Deep Learning-Based Classification Consisting of Pre-Trained Models and Proposed Model Using K-Fold Cross-Validation for Pistachio Species. Applied Sciences, 15(8), 4516. https://doi.org/10.3390/app15084516

Vidyarthi, S. K., Tiwari, R., Singh, S. K., & Xiao, H. W. (2020). Prediction of size and mass of pistachio kernels using random Forest machine learning. Journal of Food Process Engineering, 43(9), e13473. https://doi.org/10.1111/jfpe.13473

Wei, Y., Qiu, X., Peng, Z., Wu, Y., Min, W., & Xu, T. (2025). Network-regularized sparse logistic regression for crop identification in remote sensing images. Journal of Applied Remote Sensing, 19(2), 028505-028505. https://doi.org/10.1117/1.jrs.19.028505

Wolpert, D. H., & Macready, W. G. (1997). No free lunch theorems for optimization. IEEE Transactions on Evolutionary Computation, 1(1), 67–82. https://doi.org/10.1109/4235.585893

Yang, L., & 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

Yao, J., Dou, J., Chen, K., Li, J., Luo, X., Wang, J., & Ren, M. (2026). A tardigrade-inspired metaheuristic algorithm for complex multimodal optimization and high-dimensional applications. Neurocomputing, 668, 132380. https://doi.org/10.1016/j.neucom.2025.132380