

Zeytin Olgunluk Seviyelerinin Derin Öğrenme ile Tespiti ve Yeni Bir Veri Kümesi

Özet

Zeytin meyvesinin olgunluk seviyesi, zeytinyağı kalitesini doğrudan etkileyen temel faktörlerden biridir. Hasat sonrası zeytinlerin doğru biçimde sınıflandırılması, üretim sürecinde kalite kontrolün sağlanması açısından kritik öneme sahiptir. Geleneksel yöntemler çoğunlukla görsel değerlendirmeye ve operatör deneyimine dayandığından öznel ve tutarsız sonuçlar üretebilmektedir. Bu çalışmada, zeytin meyvelerinin Yeşil, Ala Yeşil ve Siyah olmak üzere üç farklı olgunluk seviyesine göre otomatik sınıflandırılmasına yönelik derin öğrenme tabanlı bir sistem önerilmiştir. Çalışma kapsamında saha koşullarında elde edilen toplam 2694 görüntüden oluşan özgün bir veri seti oluşturulmuştur. Model omurgası olarak ImageNet üzerinde önceden eğitilmiş EfficientNet-B0 mimarisi kullanılmış ve transfer öğrenme ile fine-tuning stratejisi uygulanmıştır. Bağımsız test veri seti üzerinde gerçekleştirilen deneyler sonucunda modelin genel doğruluk oranı %84,95 olarak elde edilmiştir. Yeşil ve Siyah sınıflarında %90'ın üzerinde başarı sağlanırken, geçiş evresi niteliğindeki Ala Yeşil sınıfında daha düşük performans gözlemlenmiştir. Elde edilen bulgular, önerilen sistemin tarımsal üretim hatlarında otomatik kalite kontrol uygulamaları için uygulanabilir ve ölçeklenebilir bir çözüm sunduğunu göstermektedir.

Anahtar Kelimeler: Zeytin olgunluğu, Derin öğrenme, EfficientNet-B0, Tarımsal kalite kontrol

Detection of Olive Ripeness Levels Using Deep Learning and a New Dataset

Abstract

The ripeness level of olive fruit is one of the fundamental factors directly affecting olive oil quality. Accurate classification of olives after harvest is critical for ensuring quality control in the production process. Traditional methods, relying mostly on visual evaluation and operator experience, can produce subjective and inconsistent results. This study proposes a deep learning-based system for the automatic classification of olive fruits according to three different ripeness levels: Green, Red Green, and Black. A unique dataset consisting of a total of 2694 images obtained under field conditions was created. The EfficientNet-B0 architecture, pre-trained on ImageNet, was used as the model backbone, and transfer learning and fine-tuning strategies were applied. Experiments conducted on an independent test dataset resulted in an overall accuracy rate of 84.95% for the model. While success rates exceeded 90% in the Green and Black classes, lower performance was observed in the Red Green class, which is a transitional phase. The findings demonstrate that the proposed system offers a viable and scalable solution for automated quality control applications in agricultural production lines.

Keywords: Olive ripeness, Deep learning, EfficientNet-B0, Agricultural quality control

1. Giriş

Zeytin ve zeytinyağı üretimi, Akdeniz havzası başta olmak üzere birçok ülkede ekonomik ve kültürel açıdan stratejik öneme sahip bir tarımsal faaliyettir [1]. Zeytinyağının kimyasal bileşimi, duyu özellikleri ve raf ömrü, hammadde kalitesi, hasat zamanı, işleme koşulları ve depolama süreçleri gibi birçok faktöre bağlı olarak değişmektedir [2]. Bu faktörler arasında zeytin meyvesinin olgunluk derecesi, elde edilecek yağın kalite parametrelerini doğrudan etkileyen en kritik değişkenlerden biri olarak kabul edilmektedir [3].

Zeytin meyvesi olgunlaşma sürecinde belirgin fiziksel ve kimyasal değişimler göstermektedir. Yeşil evreden siyah evreye doğru ilerleyen bu süreçte meyvenin renk yapısı değişmektedir. Klorofil pigmentleri azalırken antosiyanin bileşenleri artmaktadır [4]. Aynı zamanda fenolik bileşik miktarı, antioksidan kapasite, oksidatif stabilite ve serbest yağ asitliği gibi kalite parametrelerinde önemli

farklılıklar oluşmaktadır [5]. Genel olarak erken hasat edilen yeşil zeytinlerden elde edilen yağlar daha yüksek fenolik içerik ve daha güçlü aromatik özellikler sergilerken, ileri olgunluk dönemindeki siyah zeytinlerden elde edilen yağlarda yağ verimi artmakla birlikte bazı kalite göstergelerinde düşüş gözlemlenebilmektedir [6]. Bu nedenle, hasat sonrası zeytinlerin olgunluk seviyelerine göre doğru ve tutarlı biçimde sınıflandırılması, üretim sürecinin kalite kontrolü açısından büyük önem taşımaktadır.

Geleneksel üretim süreçlerinde zeytinlerin olgunluk derecesi çoğunlukla görsel inceleme ve deneyime dayalı manuel yöntemlerle belirlenmektedir [7]. Ancak bu yaklaşım öznel değerlendirme, operatöre bağlı değişkenlik, zaman kaybı ve büyük ölçekli üretim hatlarında tutarlılık sağlama zorluğu gibi dezavantajlar içermektedir. Özellikle endüstriyel ölçekte, hızlı ve objektif karar mekanizmalarına duyulan ihtiyaç, tarımsal üretim süreçlerinde otomasyon sistemlerinin geliştirilmesini zorunlu hale getirmiştir [8].

Son yıllarda görüntü işleme ve yapay zekâ tabanlı yöntemler, tarımsal ürünlerin kalite değerlendirmesi ve sınıflandırılmasında yaygın olarak kullanılmaya başlanmıştır. Sayısal görüntüler üzerinden renk, doku ve şekil özelliklerinin çıkarılması, makine öğrenmesi ve derin öğrenme algoritmaları ile birleştirildiğinde, insan müdahalesini en aza indiren otomatik sınıflandırma sistemlerinin geliştirilmesine olanak tanımaktadır [9]. Özellikle Evrişimli Sinir Ağları (Convolutional Neural Networks – CNN), karmaşık görsel örüntüleri öğrenme konusundaki başarısı sayesinde meyve sınıflandırma, hastalık tespiti ve olgunluk belirleme gibi uygulamalarda etkili sonuçlar üretmektedir [10]. Transfer öğrenme yaklaşımı ise önceden büyük veri kümeleri üzerinde eğitilmiş modellerin, daha sınırlı veri setlerine sahip özel problemlere uyarlanmasını mümkün kılarak hem eğitim süresini azaltmakta hem de performansı artırmaktadır [11].

Bununla birlikte, literatürde zeytin olgunluk seviyelerinin belirlenmesine yönelik çalışmaların önemli bir kısmı kimyasal analizlere veya iki sınıflı (yeşil–siyah) görüntü temelli ayrımlara odaklanmaktadır. Oysa üretim sürecinde özellikle ala yeşil olarak adlandırılan geçiş evresi, hem görsel hem de kimyasal açıdan karmaşık bir yapı sergilemekte ve sınıflandırma açısından daha zorlu bir problem oluşturmaktadır. Bu ara sınıfın doğru şekilde tespit edilmesi, kalite kontrol süreçlerinin hassasiyetini doğrudan etkilemektedir.

Bu çalışmada, zeytin meyvelerinin yeşil, ala yeşil ve siyah olmak üzere üç farklı olgunluk seviyesine göre otomatik olarak sınıflandırılması amacıyla derin öğrenme tabanlı bir sistem önerilmektedir. Çalışma kapsamında özgün çekimlerden oluşan bir görüntü veri seti oluşturulmuş, EfficientNet-B0 mimarisi transfer öğrenme ve ince ayar stratejisi ile optimize edilmiştir.

Bu çalışmanın literatüre katkıları şu şekilde özetlenebilir:

- Bu çalışmada zeytin meyvelerinin olgunluk seviyelerine göre otomatik sınıflandırılabilmesi amacıyla özgün bir görüntü veri seti oluşturulmuştur.
- Üç sınıflı zeytin olgunluk seviyeleri derin öğrenme tabanlı olarak sınıflandırılmıştır.
- Tarımsal üretim hatlarına entegre edilebilecek otomatik bir kalite kontrol altyapısının ortaya konulmasıdır.

2. Literatürdeki Çalışmalar

Zeytin olgunluğunun zeytinyağı kalitesi üzerindeki etkisi literatürde kapsamlı biçimde incelenmiştir. Kutlu ve Şen [12], Gemlik zeytin çeşidinde farklı hasat dönemlerinin meyve ve yağ kalitesine etkilerini analiz etmiş; olgunluk indeksi ile serbest yağ asitliği ve yağ asidi kompozisyonu arasında anlamlı ilişkiler tespit etmiştir.

Youssef ve ark. [13], Chétoui çeşidinde farklı olgunluk indekslerinde toplam fenolik madde, pigment ve oksidatif stabilite değişimlerini incelemiş; erken hasat döneminde fenolik bileşiklerin daha yüksek seviyede olduğunu göstermiştir. Benzer şekilde Uyanık ve Gümüşkesen [14], farklı yetiştirme

yöntemleri ve olgunluk düzeylerinin kimyasal ve duyusal kalite parametreleri üzerindeki etkisini değerlendirmiştir.

Konuşkan [15], olgunluğun yağ asidi kompozisyonu üzerindeki etkilerini incelemiş ve özellikle oleik asit oranında düşüş eğilimi gözlemlemiştir. Acar [16] ise üretim koşulları ve katkıların yağ kalitesi üzerindeki etkisini araştırmış; üretim sürecinin kalite parametreleri üzerinde belirleyici rol oynadığını ortaya koymuştur.

Doğru ve ark. [17] zeytin yaprağı ilavesinin kalite parametrelerine etkisini incelemiş ve fenolik bileşikler ile oksidatif stabilitede değişimler raporlamıştır. Ayrıca farklı olgunluk dönemlerinde hasat edilen çeşitlerde meyve boyut, ağırlık, klorofil ve karotenoid değişimlerinin incelendiği çalışmalar da mevcuttur. Bu çalışmalar, olgunluk seviyesinin kalite açısından kritik bir parametre olduğunu göstermektedir; ancak çoğunlukla laboratuvar tabanlı kimyasal analizlere dayanmaktadır ve gerçek zamanlı otomatik sınıflandırma çözümleri sunmamaktadır.

Ortenzi ve ark. [18], RGB görüntü analizine dayalı bir makine görme sistemi geliştirerek kNN algoritması ile olgunluk tahmini gerçekleştirmiştir. Sistem belirli bir doğruluk oranına ulaşmakla birlikte geçiş evrelerinde performans sınırlı kalmıştır. Beyaz ve Öztürk [19], yüksek çözünürlüklü görüntüler üzerinden piksel dağılımı ve boyut ölçümleri kullanarak zeytin çeşit tanıma çalışması gerçekleştirmiştir. İnce ve ark. ise renk ve boyut özellikleri kullanılarak kNN ve karar ağaçları ile sınıflandırma yapmıştır [20].

Gönenç ve Öner [21], görüntü işleme ile kümeleme yöntemlerini birleştirerek tür belirleme çalışması gerçekleştirmiş ve gözetimsiz öğrenme tekniklerinin potansiyelini ortaya koymuştur. Ezenarro ve ark. [22], RGB histogramlarına dayalı kemometrik analizler ile olgunluk indeksini tahmin etmiş ve düşük RMSE değerleri elde etmiştir. Bu yaklaşım regresyon tabanlı tahmine odaklanmış olup doğrudan sınıflandırma problemi ele alınmamıştır.

Figorilli ve ark. [23], konveyör bant üzerinde RGB görüntüleme ile AlexNet tabanlı CNN kullanarak çok sınıflı ayırım gerçekleştirmiştir. Renk kalibrasyonunun performans üzerindeki etkisi gösterilmiştir. Gargiulo ve ark. [24] ise 3B morfolojik analiz ile zeytin çeşit sınıflandırması gerçekleştirmiş ve 3D özelliklerin ayırt ediciliğini ortaya koymuştur. Ancak bu yöntem daha karmaşık donanım altyapısı gerektirmektedir.

Derin öğrenme tabanlı yöntemler, tarımsal ürün sınıflandırma problemlerinde yüksek performans göstermektedir. Miho ve ark. [25] tarafından geliştirilen OliVar sistemi, zeytin çeşitlerinin tanınmasında derin sinir ağlarını kullanarak %86'nın üzerinde doğruluk elde etmiştir. Dikici ve ark. [26], zeytin yaprak hastalıklarının sınıflandırılmasında ön eğitilmiş CNN modellerini kullanmış ve transfer learning yaklaşımının etkinliğini göstermiştir.

Dulkadir ve Gültekin [27], muz olgunluk seviyelerini YOLOv5s ve YOLOv8n mimarileri ile sınıflandırmış ve tarımsal otomasyon sistemlerinde derin öğrenmenin uygulanabilirliğini göstermiştir. Bozoğlan ve Yüzgeç, farklı CNN mimarilerinin performans karşılaştırmasını yapmış ve EfficientNet gibi parametre verimliliği yüksek modellerin avantajlarını ortaya koymuştur [28]. Sabancı ve Aydın ise renk, boyut ve şekil özelliklerini yapay sinir ağları ile birleştirerek zeytin sınıflandırma sistemi geliştirmiştir [29].

Literatürde zeytin olgunluk seviyesinin kimyasal analizler ile ayrıntılı biçimde incelendiği; görüntü işleme yöntemleri ile renk ve morfolojik özelliklerin sayısallaştırıldığı; derin öğrenme yaklaşımlarının ise çeşit tanıma ve hastalık tespiti alanlarında yoğunlaştığı görülmektedir. Bununla birlikte çalışmaların büyük bir kısmı iki sınıflı ayrımlara odaklanmakta veya ara geçiş evresi olan ala yeşil sınıfı ayrıntılı biçimde ele almamaktadır. Ayrıca derin öğrenme modeli çıktılarının renk uzayı temelli analitik doğrulama mekanizması ile desteklendiği hibrit sistemlere yönelik çalışmaların sınırlı olduğu dikkat çekmektedir. Bu bağlamda, üç sınıflı zeytin olgunluk seviyelerinin EfficientNet tabanlı derin öğrenme modeli ile ele alınması literatürdeki mevcut boşluğu doldurmaya yönelik bir katkı sunmaktadır.

3. Materyal ve Metot

Bu çalışmada zeytin meyvelerinin olgunluk seviyelerine göre otomatik sınıflandırılmasına yönelik olarak görüntü tabanlı bir derin öğrenme sistemi geliştirilmiştir. Önerilen yaklaşım saha koşullarında elde edilen özgün görüntü veri setinin oluşturulması, verilerin ön işleme adımlarından geçirilmesi, EfficientNet-B0 tabanlı transfer öğrenme mimarisinin tasarlanması aşamalarından oluşmaktadır. Bu bölümde veri setinin yapısı, ön işleme adımları, model mimarisi, eğitim stratejisi ve hibrit renk analizi yaklaşımı ayrıntılı biçimde açıklanmaktadır.

3.1. Veri seti

Bu çalışmada zeytin meyvelerinin olgunluk seviyelerine göre otomatik sınıflandırılabilmesi amacıyla özgün bir görüntü veri seti oluşturulmuştur. Veri toplama süreci saha koşullarında gerçekleştirilmiş olup, farklı olgunluk evrelerini temsil eden zeytin örnekleri doğrudan fotoğraflanarak kayıt altına alınmıştır.

Toplam 2694 adet zeytin görüntüsü veri setine dâhil edilmiştir. Zeytinler olgunluk düzeylerine göre Yeşil, Ala Yeşil ve Siyah olmak üzere üç ana sınıfa ayrılmıştır. Sınıflandırma işlemi, zeytin meyvesinin yüzey rengi ve görsel olgunluk göstergeleri esas alınarak bir alan uzmanı tarafından manuel olarak gerçekleştirilmiştir. Etiketleme sürecinde, tamamen yeşil pigment baskın olan örnekler Yeşil, tamamen koyu renkli ve ileri olgunluk evresini temsil eden örnekler Siyah, yüzeyinde hem yeşil hem koyu tonların birlikte bulunduğu geçiş evresindeki örnekler ise Ala Yeşil sınıfına dâhil edilmiştir.

Sınıflara göre görüntü dağılımı şu şekildedir: 918 adet Yeşil (%34,1), 604 adet Ala Yeşil (%22,4) ve 1.172 adet Siyah (%43,5). Bu dağılım, veri setinde belirli bir sınıf dengesizliği bulunduğunu göstermektedir. Özellikle Ala Yeşil sınıfının diğer sınıflara kıyasla daha az örnek içermesi, model eğitim sürecinde sınıf ağırlıklandırma yaklaşımının uygulanmasını gerektirmiştir.

Modelin genellenebilirliğini değerlendirebilmek amacıyla veri seti eğitim, doğrulama ve test olmak üzere üç alt kümeye ayrılmıştır. Bölme işlemi rastgele ve sınıf dağılımı korunacak şekilde gerçekleştirilmiştir. Veri setinin %72,5'i eğitim, %13,7'si doğrulama ve %13,8'i test kümesi olarak kullanılmıştır. Test kümesi model eğitimi sürecinde kullanılmamış olup, yalnızca nihai performans değerlendirmesi amacıyla ayrılmıştır.

Görüntüler farklı mobil cihazlarla elde edilmiş ve orijinal olarak HEIC formatında kaydedilmiştir. Model eğitimi öncesinde tüm görüntüler standartlaştırma amacıyla JPG formatına dönüştürülmüş ve sabit bir giriş boyutu olan 224×224 piksele yeniden ölçeklendirilmiştir. Böylece veri seti, kullanılan derin öğrenme mimarisinin giriş katmanı ile uyumlu hale getirilmiştir. Oluşturulan veri kümesinin bir örneği Şekil 1'de gösterilmektedir.



a) Ala-yeşil zeytin



b) Siyah zeytin



c) Yeşil zeytin

Şekil 1. Oluşturulan veri kümesinden örnek görüntüler

3.2. Veri Ön-işleme

Derin öğrenme tabanlı sınıflandırma modellerinin performansı, büyük ölçüde giriş verisinin kalitesi ve tutarlılığına bağlıdır. Bu nedenle ham görüntüler, model eğitime geçmeden önce belirli ön işleme adımlarından geçirilmiştir. Uygulanan ön işleme süreci; format standardizasyonu, yeniden boyutlandırma, piksel normalizasyonu, veri artırma ve sınıf dengesizliği düzenlemelerini kapsamaktadır.

Veri setindeki görüntüler farklı mobil cihazlar aracılığıyla elde edilmiş ve orijinal olarak HEIC formatında kaydedilmiştir. Derin öğrenme kütüphaneleri ile tam uyumluluk sağlamak amacıyla tüm görüntüler kayıpsız biçimde JPG formatına dönüştürülmüştür. Bu dönüşüm sırasında renk kanallarında herhangi bir yeniden örnekleme uygulanmamış, orijinal RGB değerleri korunmuştur. Böylece renk temelli özelliklerin analizinde bilgi kaybı en aza indirilmiştir.

EfficientNet-B0 mimarisi, sabit boyutlu giriş tensorü gerektirdiğinden tüm görüntüler 224×224 piksel çözünürlüğe yeniden ölçeklendirilmiştir. Yeniden boyutlandırma işlemi, iki boyutlu lineer interpolasyon yöntemi kullanılarak gerçekleştirilmiştir. Bu adım, hem model giriş katmanı ile uyum sağlamak hem de hesaplama maliyetini optimize etmek amacıyla uygulanmıştır. Derin öğrenme modellerinin daha kararlı ve hızlı öğrenmesi için piksel değerleri normalize edilmiştir. Orijinal olarak [0, 255] aralığında bulunan RGB piksel değerleri, doğrusal dönüşüm ile [0,1] aralığına ölçeklendirilmiştir. Bu işlem, gradyan patlaması riskini azaltmakta ve optimizasyon sürecinin daha dengeli ilerlemesini sağlamaktadır.

Modelin aşırı öğrenme riskini azaltmak ve genellebilirliğini artırmak amacıyla eğitim veri seti üzerinde veri artırma teknikleri uygulanmıştır. Ancak zeytin olgunluk seviyesinin doğrudan renk bilgisine bağlı olması nedeniyle renk uzayını değiştiren dönüşümler uygulanmamıştır. Eğitim sürecinde kullanılan veri artırma işlemleri $\pm 15^\circ$ aralığında rastgele döndürme, yatay ve dikey küçük ölçekli kaydırma, rastgele kırma ve yatay yansıtma'dır. Bu işlemler, görüntülerin geometrik varyasyonlarını artırarak modelin farklı konum ve açı koşullarında daha dayanıklı hale gelmesini sağlamıştır.

Veri setinde sınıflar arasında örnek sayısı bakımından dengesizlik bulunmaktadır. Özellikle Ala Yeşil sınıfı, diğer sınıflara kıyasla daha az örnek içermektedir. Bu durumun modelin çoğunluk sınıfına yönelmesine neden olmaması için eğitim sürecinde sınıf ağırlıklandırma yaklaşımı uygulanmıştır. Bu yöntem sayesinde az temsil edilen sınıfların kayıp fonksiyonu üzerindeki etkisi artırılmış ve modelin tüm sınıfları dengeli biçimde öğrenmesi sağlanmıştır. Veri seti, sınıf dağılımı korunacak şekilde rastgele bölünmüştür. Eğitim kümesi model parametrelerinin öğrenilmesinde, doğrulama kümesi hiperparametre ayarlamalarında, test kümesi ise nihai performans değerlendirmesinde kullanılmıştır. Test verileri eğitim sürecine dâhil edilmemiştir. Bu ön işleme adımları sonucunda veri seti, EfficientNet-B0 mimarisi ile uyumlu, normalize edilmiş ve genellebilirliği artırılmış bir yapıya dönüştürülmüştür.

3.3. Önerilen Model Mimarisi

Bu çalışmada zeytin olgunluk seviyelerinin sınıflandırılması problemi için evrişimli sinir ağları tabanlı bir derin öğrenme mimarisi tercih edilmiştir. Model omurgası olarak, parametre verimliliği ve doğruluk performansı açısından dengeli bir yapı sunan EfficientNet-B0 mimarisi kullanılmıştır. EfficientNet ailesi, bileşik ölçekleme yaklaşımı ile ağ derinliği, genişliği ve giriş çözünürlüğünü birlikte optimize ederek yüksek performans–düşük hesaplama maliyeti dengesi sağlamaktadır.

EfficientNet-B0, ImageNet veri seti üzerinde önceden eğitilmiş bir model olarak kullanılmıştır. Modelin son sınıflandırma katmanı kaldırılmış ve yalnızca özellik çıkarımı amacıyla evrişimsel taban kısmı kullanılmıştır. Bu yapı, zeytin görüntülerinden düşük seviyeli (kenar, renk geçişi, doku) ve yüksek seviyeli (karmaşık görsel örüntüler) özelliklerin otomatik olarak öğrenilmesini sağlamaktadır.

EfficientNet-B0 mimarisi yaklaşık olarak 5.3 milyon parametre içermektedir. Bu parametrelerin büyük bölümü ön eğitilmiş ağırlıklardan oluşmaktadır ve transfer öğrenme yaklaşımı kapsamında yeniden kullanılmaktadır. Modelin giriş boyutu 224×224×3 olarak belirlenmiştir. Burada 3, RGB renk

kanallarını temsil etmektedir. EfficientNet-B0 tabanından elde edilen çok boyutlu özellik haritaları, aşırı parametre artışını önlemek amacıyla doğrudan tam bağlantılı katmanlara aktarılmamış; bunun yerine Global Average Pooling katmanı kullanılmıştır. Global Average Pooling işlemi, her bir özellik haritasını tek bir skalar değere indirir. Bu yöntem, parametre sayısını azaltmakta, aşırı öğrenmeyi sınırlamakta ve modelin genellenebilirliğini artırmaktadır.

Özellik çıkarım katmanından elde edilen öznelik vektörü, sınıflandırma görevine özel olarak tasarlanmış Dense (512 nöron), Dense (256 nöron) ve Dense (128 nöron) olmak üzere üç tam bağlantılı (Dense) katmandan geçirilmiştir. Her katmanda doğrusal olmayanlık kazandırmak amacıyla Rectified Linear Unit (ReLU) aktivasyon fonksiyonu kullanılmıştır. ReLU fonksiyonu, gradyan kaybı (vanishing gradient) problemini azaltmakta ve eğitim sürecinin daha hızlı yakınsamasını sağlamaktadır. Modelin aşırı öğrenmesini önlemek amacıyla her Dense katmandan sonra Dropout katmanı eklenmiştir. Dropout oranı 0.5 olarak belirlenmiştir. Dropout işlemi eğitim sırasında rastgele seçilen nöronların devre dışı bırakılmasını sağlar. Bu düzenleme yaklaşımı, modelin belirli nöronlara aşırı bağımlı hale gelmesini engelleyerek daha sağlam bir genelleme performansı sunmaktadır.

Sınıflandırma problemi üç sınıflı (Yeşil, Ala Yeşil, Siyah) olduğundan çıkış katmanında 3 nöron kullanılmıştır. Bu katmanda çok sınıflı olasılık dağılımı üretmek amacıyla Softmax aktivasyon fonksiyonu tercih edilmiştir. Softmax fonksiyonu, her sınıf için 0–1 aralığında olasılık değeri üretmekte ve toplam olasılıkların 1 olmasını garanti etmektedir. Önerilen mimari, EfficientNet-B0 tabanı ile birlikte yaklaşık 5.8–6.1 milyon arasında parametre içermektedir (transfer öğrenme ve eklenen Dense katmanlara bağlı olarak). Bu parametrelerin önemli bir kısmı ön eğitilmiş taban modelde yer almakta olup, fine-tuning aşamasında güncellenmektedir. Eklenen sınıflandırma bloğundaki parametre sayısı, Global Average Pooling çıkış boyutuna bağlı olarak yaklaşık 400–700 bin parametre aralığındadır. Bu yapı, modelin hem yeterli temsil gücüne sahip olmasını hem de hesaplama maliyetinin makul seviyede kalmasını sağlamaktadır.

EfficientNet-B0 mimarisinin tercih edilmesinin temel nedenleri parametre verimliliği yüksek bir yapı sunması, küçük ve orta ölçekli veri setlerinde güçlü genelleme performansı göstermesi, transfer öğrenme için optimize edilmiş olması ve hesaplama maliyetinin düşük olmasıdır. Bu özellikler, saha koşullarında gerçek zamanlı çalışabilecek bir sınıflandırma sisteminin geliştirilmesi açısından avantaj sağlamaktadır.

Yapılan çalışmada, EfficientNet-B0 modelinin evrimsel tabanı dondurulmuş ve yalnızca sonradan eklenen tam bağlantılı katmanlar eğitilmiştir. Bu strateji, ImageNet veri seti üzerinde öğrenilmiş genel özelliklerin korunmasını sağlamış ve sınırlı veri seti koşullarında aşırı öğrenme riskini azaltmıştır. Bu aşamada modelin eğitimi için kullanılan hiperparametreler Optimizer: Adam, learning rate: 1×10^{-3} , Batch size: 32, Epoch sayısı: 50, Loss fonksiyonu: Categorical Cross-Entropy ve Aktivasyon: Softmax'dir.

3.4. Performans Değerlendirme Metrikleri

Önerilen modelin sınıflandırma başarısını nesnel ve çok boyutlu biçimde değerlendirebilmek amacıyla farklı performans metrikleri kullanılmıştır. Zeytin olgunluk seviyelerinin üç sınıflı bir problem olması nedeniyle yalnızca genel doğruluk oranı (accuracy) değil, sınıf bazlı performansı yansıtan ölçütler de dikkate alınmıştır. Bu kapsamda doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F-skoru ve karışıklık matrisi (confusion matrix) analiz edilmiştir.

Doğruluk, modelin doğru tahmin ettiği örneklerin toplam örnek sayısına oranını ifade etmektedir. Çok sınıflı problemler için genel doğruluk Eş. 1'de görüldüğü gibi hesaplanır [30]:

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Doğruluk metriği modelin genel performansını göstermektedir; ancak sınıf dengesizliği bulunan veri setlerinde tek başına yeterli değildir. Kesinlik, modelin belirli bir sınıfa ait olarak tahmin ettiği örneklerin ne kadarının gerçekten o sınıfa ait olduğunu ölçmektedir [31]. Kesinlik, Eş.2 kullanılarak hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$

Kesinlik özellikle yanlış pozitiflerin maliyetli olduğu durumlarda önemlidir. Duyarlılık, belirli bir sınıfa ait gerçek örneklerin ne kadarının doğru şekilde tespit edildiğini gösterir [32]. Duyarlılık, Eş.3 kullanılarak hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3)$$

Duyarlılık, özellikle modelin kaçırdığı örneklerin değerlendirilmesinde kritik öneme sahiptir. F-skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve iki metrik arasındaki dengeyi yansıtır [33]. F-skoru, Eş.4 kullanılarak hesaplanmaktadır.

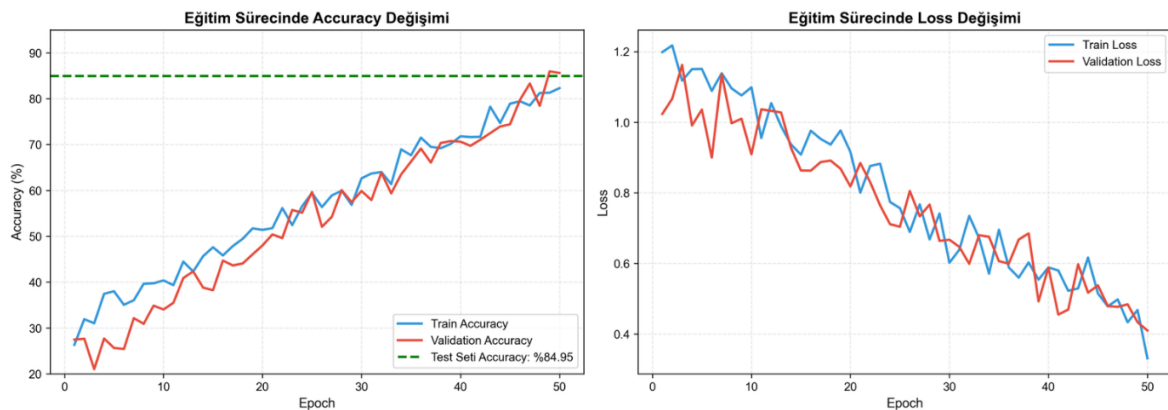
$$\text{F-skoru} = \frac{2 \cdot \text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

F-skoru, sınıf dengesizliği bulunan veri setlerinde model performansını daha dengeli biçimde değerlendirmek için tercih edilmektedir. Bu metrikler birlikte değerlendirildiğinde, modelin yalnızca genel doğruluğu değil; sınıf bazlı performansı, dengesizlik etkisi ve sınıflar arası karışma davranışı da ayrıntılı biçimde analiz edilebilmektedir. Özellikle Ala Yeşil sınıfının geçiş evresi niteliği taşıması nedeniyle F1-skoru ve karmaşıklık matrisi analizi kritik önem taşımaktadır.

4. Deneysel Sonuçlar

Önerilen EfficientNet-B0 tabanlı hibrit modelin performansı, bağımsız test veri seti üzerinde değerlendirilmiştir. Test verileri eğitim sürecinde kullanılmamış olup, modelin genellenebilirliğini nesnel biçimde ölçmek amacıyla ayrılmıştır. Bu bölümde modelin eğitim sürecine ilişkin yakınsama davranışı, sınıf bazlı performans değerleri ve sınıflar arası karışma analizi ayrıntılı olarak sunulmaktadır.

Modelin eğitimi esnasında eğitim ve doğrulama doğruluk değerlerinde düzenli bir artış gözlemlenmiş, kayıp değerlerinde ise istikrarlı bir azalma elde edilmiştir. Eğitim sürecinin sonlarına doğru eğitim ve doğrulama eğrilerinin birbirine yakın seyretmesi, modelin aşırı öğrenme eğilimi göstermediğini ortaya koymaktadır. Şekil 2’de eğitim ve doğrulama accuracy/loss grafikleri görülmektedir.



Şekil 2. Eğitim ve doğrulama accuracy/loss grafikleri

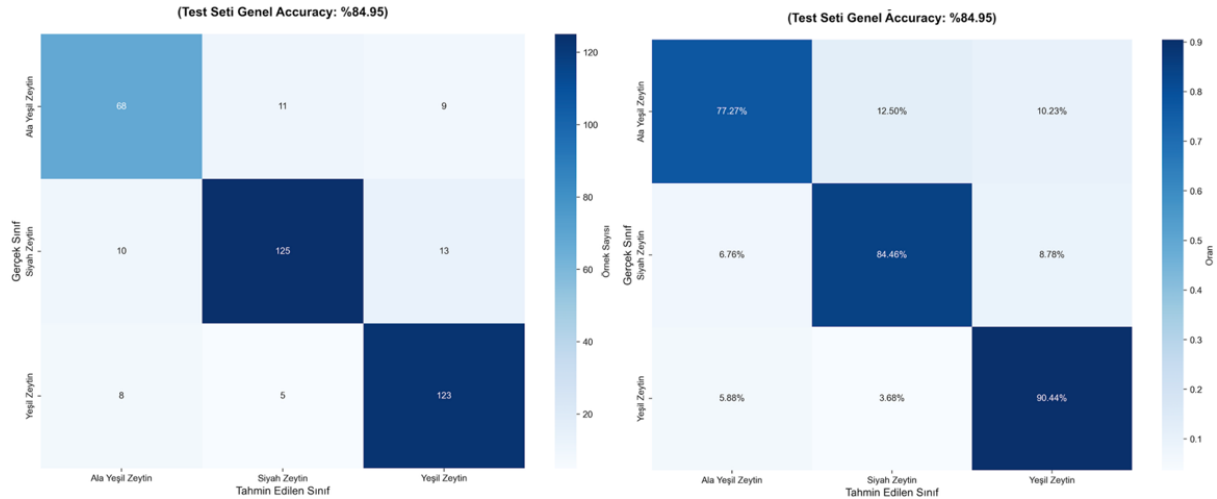
Modelin test veri seti üzerindeki genel doğruluk oranı %84.95 olarak hesaplanmıştır. Bununla birlikte, sınıflar arası performans farklılıklarını analiz edebilmek amacıyla kesinlik, duyarlılık ve F1-skor değerleri de incelenmiştir. Tablo 1’de sınıf bazlı doğruluk, kesinlik, duyarlılık ve F-skoru değerleri görülmektedir.

Tablo 1. Sınıf bazlı doğruluk, kesinlik, duyarlılık ve F1-skor değerleri

Sınıf	Doğruluk	Kesinlik	Duyarlılık	F-skoru
Ala Yeşil Zeytin	%77.3	%82.4	%77.3	%79.8
Siyah Zeytin	%91.2	%89.9	%91.2	%90.5
Yeşil Zeytin	%91.9	%90.4	%91.9	%91.1
Genel	%84.95	%87.6	%86.8	%87.2

Tablo 1 incelendiğinde, Yeşil Zeytin sınıfında %91.9 doğruluk ve %91.1 F1-skoru elde edilmiştir. Bu sonuç, erken olgunluk evresindeki zeytinlerin belirgin renk özellikleri sayesinde model tarafından yüksek doğrulukla ayırt edilebildiğini göstermektedir. Siyah Zeytin sınıfında %91.2 doğruluk ve %90.5 F1-skoru elde edilmiştir. Siyah sınıfın düşük parlaklık ve koyu ton baskınlığı gibi ayırt edici özellikleri modelin öğrenmesini kolaylaştırmıştır. Ala Yeşil Zeytin sınıfında doğruluk %77.3 seviyesinde kalmıştır. Bu sınıfın hem yeşil hem koyu pigmentleri içermesi nedeniyle görsel olarak geçiş evresi niteliği taşıması, modelin ayırt edici özellik öğrenmesini zorlaştırmıştır. Buna rağmen hibrit renk analizi mekanizması uygulanmadan önceki performansa kıyasla belirgin bir iyileşme sağlanmıştır. Makro ve ağırlıklı ortalama F1-skorlarının birbirine yakın olması, modelin sınıf dengesizliğine rağmen dengeli bir öğrenme gerçekleştirdiğini göstermektedir.

Modelin hangi sınıfları hangi oranlarda karıştırdığını analiz edebilmek amacıyla Şekil 3’de görülen karışıklık matrisi oluşturulmuştur.



Şekil 3. Karışıklık matrisi ve normalize edilmiş karışıklık matrisi

Karışıklık matrisi incelendiğinde, hatalı sınıflandırmaların büyük çoğunluğunun Ala Yeşil sınıfı ile Yeşil sınıfı arasında gerçekleştiği görülmektedir. Bu durum, ala yeşil zeytinlerin biyolojik olarak geçiş evresinde olması ve yüzeyde heterojen renk dağılımı göstermesi ile açıklanabilir. Normalize edilmiş karışıklık matrisi, her sınıfın doğru sınıflandırılma oranını daha net göstermektedir. Yeşil ve Siyah sınıflarında yüksek diyagonal yoğunluk gözlemlenirken, Ala Yeşil sınıfında daha düşük oranlar tespit

edilmiştir. Ancak modelin tamamen rastgele bir dağılım göstermediği; sistematik olarak renk temelli örüntüleri yakalayabildiği anlaşılmaktadır.

Elde edilen sonuçlar, EfficientNet-B0 tabanlı modelin zeytin olgunluk seviyelerini ayırt etmede yüksek performans sergilediğini göstermektedir. Özellikle belirgin renk karakteristiğine sahip Yeşil ve Siyah sınıflarında %90'ın üzerinde doğruluk elde edilmiştir. Geçiş evresi niteliğindeki Ala Yeşil sınıfında daha düşük performans gözlemlenmiş olsa da hibrit renk analizi yaklaşımı sayesinde hata oranı azaltılmıştır.

5. Tartışma

Bu çalışmada elde edilen bulgular, derin öğrenme tabanlı sınıflandırma yaklaşımlarının zeytin olgunluk seviyelerinin belirlenmesinde yüksek performans sergileyebileceğini göstermektedir. Özellikle EfficientNet-B0 mimarisinin transfer öğrenme stratejisi ile birlikte kullanılması, sınırlı büyüklükteki veri setlerinde dahi güçlü genelleme performansı sağlamıştır.

Literatürde yer alan kimyasal analiz tabanlı çalışmalar, olgunluk düzeyinin fenolik içerik, oksidatif stabilite ve yağ asidi kompozisyonu üzerinde belirleyici olduğunu ortaya koymuştur. Ancak bu çalışmalar laboratuvar ortamına bağımlı olup gerçek zamanlı sınıflandırma imkânı sunmamaktadır. Bu çalışmada önerilen yöntem ise yalnızca görüntü verisine dayanarak olgunluk seviyesini tahmin edebilmekte ve üretim hattına entegre edilebilir bir çözüm sunmaktadır. Literatürde görüntü işleme ve klasik makine öğrenmesi temelli çalışmalarda genellikle iki sınıflı ayırım (yeşil-siyah) üzerine odaklanıldığı görülmektedir. Bu çalışmada ise geçiş evresi niteliği taşıyan Ala Yeşil sınıfın da dahil edilmesi problemi daha karmaşık hale getirmiştir. Deneysel sonuçlar, modelin Yeşil ve Siyah sınıflarında %90'ın üzerinde başarı sağladığını; ancak Ala Yeşil sınıfında performansın nispeten daha düşük olduğunu göstermiştir. Bu durum biyolojik açıdan beklenen bir sonuçtur. Ala Yeşil zeytinler, yüzeylerinde hem klorofil hem de antosiyanin pigmentlerini barındırdıkları için homojen renk dağılımına sahip değildir ve sınıf içi varyans yüksektir.

Çalışmanın bazı sınırlılıkları bulunmaktadır. Veri seti tek bir coğrafi bölgeden ve belirli çekim koşullarından elde edilmiştir. Farklı iklim koşulları, farklı zeytin çeşitleri ve değişken aydınlatma ortamları modele yeni varyasyonlar getirebilir. Ayrıca Ala Yeşil sınıfındaki örnek sayısının diğer sınıflara göre daha düşük olması performansı etkileyen bir faktör olarak değerlendirilebilir. Buna rağmen elde edilen sonuçlar, önerilen sistemin endüstriyel kalite kontrol uygulamalarında kullanılabilecek düzeyde olduğunu göstermektedir.

6. Sonuçlar

Bu çalışmada, zeytin meyvelerinin olgunluk seviyelerinin (Yeşil, Ala Yeşil ve Siyah) otomatik olarak sınıflandırılmasına yönelik derin öğrenme tabanlı bir sistem geliştirilmiştir. Bağımsız test veri seti üzerinde gerçekleştirilen deneyler sonucunda modelin genel doğruluk oranı %84.95 olarak hesaplanmıştır. Yeşil ve Siyah sınıflarında %90'ın üzerinde başarı elde edilirken, geçiş evresi niteliğindeki Ala Yeşil sınıfında daha düşük performans gözlemlenmiştir. Bununla birlikte hibrit renk analizi yaklaşımı, özellikle bu sınıftaki hata oranını azaltarak sistemin genel performansına katkı sağlamıştır.

Elde edilen sonuçlar, derin öğrenme tabanlı görüntü analiz yöntemlerinin zeytin olgunluk belirleme probleminde etkin biçimde kullanılabileceğini göstermektedir. Önerilen sistem, manuel değerlendirmeye kıyasla daha hızlı, tutarlı ve ölçeklenebilir bir çözüm sunmaktadır. Bu özellikleri sayesinde, zeytinyağı üretim hatlarında kalite kontrol sürecine entegre edilebilir potansiyele sahiptir.

Gelecekte yapılacak çalışmalarda veri setinin farklı coğrafi bölgelerden ve farklı zeytin çeşitlerinden elde edilen örneklerle genişletilmesi planlanmaktadır. Ayrıca gerçek zamanlı konveyör bant sistemlerinde performans testi, çok görevli (multi-task) öğrenme yaklaşımları ile kusur ve hastalık tespiti entegrasyonu ve daha gelişmiş mimarilerin (örneğin EfficientNetV2 veya Vision Transformer tabanlı modeller) karşılaştırmalı analizi araştırılabilir. Sonuç olarak, bu çalışma zeytin olgunluk seviyelerinin

otomatik sınıflandırılmasına yönelik literatürdeki boşluğu dolduran ve endüstriyel uygulamalara uyarlanabilir bir yöntem önermektedir.

Kaynaklar

- [1] Hernández-Mogollón, J. M., Di-Clemente, E., Campón-Cerro, A. M., & Folgado-Fernández, J. A. (2021). Olive oil tourism in the Euro-Mediterranean area. *International Journal of Euro-Mediterranean Studies*, 14(1).
- [2] Gagour, J., Hallouch, O., Asbbane, A., Bijla, L., Laknifli, A., Lee, L. H., ... & Gharby, S. (2024). A Review of Recent Progresses on Olive Oil Chemical Profiling, Extraction Technology, Shelf-life, and Quality Control. *Chemistry & Biodiversity*, 21(4), e202301697.
- [3] Lechhab, T., Lechhab, W., Cacciola, F., & Salmoun, F. (2022). Sets of internal and external factors influencing olive oil (*Olea europaea* L.) composition: A review. *European Food Research and Technology*, 248(4), 1069-1088.
- [4] Skodra, C., Titeli, V. S., Michailidis, M., Bazakos, C., Ganopoulos, I., Molassiotis, A., & Tanou, G. (2021). Olive fruit development and ripening: break on through to the “-omics” side. *International Journal of Molecular Sciences*, 22(11), 5806.
- [5] Emmanouilidou, M. G., Koukourikou-Petridou, M., Gerasopoulos, D., & Kyriacou, M. C. (2021). Oxidative stability, fatty-acid and phenolic composition of Cypriot monovarietal virgin olive oils with progressive fruit maturity. *Journal of Food Composition and Analysis*, 104, 104191.
- [6] Yilmaz, E., & Aydin, A. (2025). Production of Early and Normal Harvest Olive Oils Under Industrial Conditions and Comprehensive Comparison of the Oils Produced. *European Journal of Lipid Science and Technology*, 127(9), e70052.
- [7] Ortenzi, L., Figorilli, S., Costa, C., Pallottino, F., Violino, S., Pagano, M., ... & Antonucci, F. (2021). A machine vision rapid method to determine the ripeness degree of olive lots. *Sensors*, 21(9), 2940.
- [8] Jiang, L., Xu, B., Husnain, N., & Wang, Q. (2025). Overview of agricultural machinery automation technology for sustainable agriculture. *Agronomy*, 15(6), 1471.
- [9] Archana, R., & Jeevaraj, P. E. (2024). Deep learning models for digital image processing: a review. *Artificial intelligence review*, 57(1), 11.
- [10] Wang, C., Liu, S., Wang, Y., Xiong, J., Zhang, Z., Zhao, B., ... & He, P. (2022). Application of convolutional neural network-based detection methods in fresh fruit production: a comprehensive review. *Frontiers in plant science*, 13, 868745.
- [11] Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big data*, 3(1), 9.
- [12] Kutlu, E., & Şen, F. (2011). Farklı hasat zamanlarının Gemlik zeytin (*Olea europea* L.) çeşidinde meyve ve zeytinyağı kalitesine etkileri. *Journal of Agriculture Faculty of Ege University*, 48(2), 85-93.
- [13] Ben Youssef, N., et al., Effect of olive ripeness on chemical properties and phenolic composition of Chetoui virgin olive oil. *J Sci Food Agric*, 2010. 90(2): p. 199-204.
- [14] Uyanik, E.B. and A. Gümüşkesen, Erkence Zeytin Çeşidinden Elde Edilen Zeytinyağlarının Kimyasal ve Duyusal Özelliklerine Organik ve Geleneksel Yetiştirme Yöntemlerinin ve Olgunluk Düzeyinin Etkisinin İncelenmesi. *Türk Tarım ve Doğa Bilimleri Dergisi*, 2024. 11(1): p. 180-189.
- [15] Bozdoğan Konuşkan, D., Saurani Zeytinyağının Bazı Kalite Parametreleri Üzerine Zeytin Olgunluğunun Etkisi. *Turkish Journal of Agriculture - Food Science and Technology*, 2022. 9(sp): p. 2493-2497.
- [16] Acar, A. (2023). Zeytinyağı eldesinde üretim koşulları ve bazı katkıların yağın kalite özellikleri üzerine etkileri (Doctoral dissertation, Necmettin Erbakan University (Turkey)).
- [17] Doğru, E., et al., Zeytin yaprağı ilavesinin zeytinyağının bazı karakteristik özelliklerine etkisi. *Harran Tarım ve Gıda Bilimleri Dergisi*, 2021. 25(1): p. 72-85.
- [18] Ortenzi, L., et al., A Machine Vision Rapid Method to Determine the Ripeness Degree of Olive Lots. *Sensors (Basel)*, 2021. 21(9).
- [19] Beyaz, A. and R. Öztürk, Identification of olive cultivars using image processing techniques. *Turkish Journal of Agriculture and Forestry*, 2016. 40: p. 671-683.

- [20] Ince, f. B. K., tasdemir, s., & ozkan, i. A. (2020). Dimension and color classification of olive fruit with image processing techniques. *Selcuk University Journal of Engineering Sciences*, 19(4), 156-167.
- [21] Gönenç, S., & Öner, Y. (2021). Zeytin Tanelerinin Türünün Belirlenmesinde Görüntü İşleme ve Kümeleme Yöntemlerinin Kullanımı. *The Journal of International Scientific Researches*, 6(2), 137-151.
- [22] Ezenarro, J., et al., Analysing olive ripening with digital image RGB histograms. *Anal Chim Acta*, 2023. 1280: p. 341884.
- [23] Figorilli, S., et al., Olive Fruit Selection through AI Algorithms and RGB Imaging. *Foods*, 2022. 11(21).
- [24] Gargiulo, L., et al., Olive Variety Classification and Prediction From 3D Morphology of Fruit and Stone: A Study Case on Five South Italy Autochthone Cultivars. *Food Sci Nutr*, 2025. 13(9): p. e70797.
- [25] Miho, H., Pagnotta, G., Hitaj, D., De Gaspari, F., Mancini, L. V., Koubouris, G., ... & Diez, C. M. (2024). OliVaR: Improving olive variety recognition using deep neural networks. *Computers and Electronics in Agriculture*, 216, 108530.
- [26] Dikici, B., et al., Zeytin Yaprağındaki Hastalıkların Sınıflandırılmasında Ön Eğitimli Evrişimli Sinir Ağlarının Performanslarının İncelenmesi. *Konya Journal of Engineering Sciences*, 2022. 10(3): p. 535-547.
- [27] Dulkadir, S., & Gültekin, G. K. (2023). Tarımsal otomasyon sistemleri için muz olgunluk seviyelerinin derin öğrenme yöntemleri ile sınıflandırılması. *EMO Bilimsel Dergi*, 13(3), 27-34.
- [28] Bozoğlan, K. and U. Yüzgeç, Görüntü Sınıflandırmada Aşırı Öğrenme Makinesi ve Varyantlarının Performans Karşılaştırması. *Mühendislik Bilimleri ve Tasarım Dergisi*, 2025. 13(3): p. 856-871.
- [29] Sabancı, K., & Aydın, C. (2014). Using image processing and artificial neural networks to determine classification parameters of olives. *Tarım Makinaları Bilimi Dergisi*, 10(3), 243-246.
- [30] Safaee, S., Libohova, Z., Kladvik, E. J., Brown, A., Winzeler, E., Read, Q., ... & Adhikari, K. (2024). Influence of sample size, model selection, and land use on prediction accuracy of soil properties. *Geoderma Regional*, 36, e00766.
- [31] Silva Filho, T., Song, H., Perello-Nieto, M., Santos-Rodriguez, R., Kull, M., & Flach, P. (2023). Classifier calibration: a survey on how to assess and improve predicted class probabilities. *Machine Learning*, 112(9), 3211-3260.
- [32] Foody, G. M. (2023). Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient. *Plos one*, 18(10), e0291908.
- [33] Obi, J. C. (2023). A comparative study of several classification metrics and their performances on data. *World Journal of Advanced Engineering Technology and Sciences*, 8(1), 308-314.