

YAPRAK HASTALIKLARININ SINIFLANDIRILABİLİMESİ İÇİN ÖNCEDEN EĞİTİLMİŞ AĞ TABANLI DERİN AĞ MODELİ

Halit ÇETİNER^{1*}

¹Teknik Bilimler MYO, Isparta Uygulamalı Bilimler Üniversitesi, Isparta, Türkiye

Geliş Tarihi/Received Date: 28.08.2021 Kabul Tarihi/Accepted Date: 30.09.2021 DOI: 10.54365/adyumbd.988049

ÖZET

Bitkiye zarar veren hastalıkların erken teşhisi, kimyasal tarım ilaçlarının tüketimini azaltmak, mali olarak tasarruf etmek ve çevreye verilen kirliliği engelleyebilmek için oldukça önemlidir. Elma ağaç yapraklarında oluşan herhangi bir hastalık durumunda, hastalık belirtilerini erken aşamada tespit edebilmek için çiftçiler uzman tarım personeline destek almak zorunda kalmaktadır. Bu durum çiftçilere büyük bir maliyet oluşturmaktadır. Bahsedilen problemi çözebilmek adına scab, rust ve her ikisinin bir arada kullanılabilmesi için çoklu hastalık gruplarını sınıflandırabilmek için Konvülsiyonel Sinir Ağı (CNN) yöntemi tabanlı derin öğrenme modeli geliştirilmiştir. Önerilen yaklaşım popüler transfer öğrenim teknikleri olan DenseNet201, MobileNetV2, ResNet50V2, ResNet101V2, ResNet152V2 algoritmalarını giriş katmanı olarak kullanan CNN katmanlarının birleşiminden oluşmaktadır. Geliştirilen yöntem farklı seviyelerde aydınlatma, gürültü, arka planı homojen olmama durumlarını içeren zorluk seviyesi yüksek bir veri seti üzerinde test edilmiştir. Test işlemlerinde önerilen CNN tabanlı yöntemle sınıflandırma doğruluk oranı olarak %97 değerine ulaşılmıştır.

Anahtar Kelimeler: CNN, elma yaprak hastalığı, sınıflandırma, transfer öğrenme

PRE-TRAINED NETWORK BASED DEEP NETWORK MODEL FOR CLASSIFICATION OF LEAF DISEASES

ABSTRACT

Early diagnosis of plant-damaging diseases is very important to reduce the consumption of chemical pesticides, to save money and to prevent pollution to the environment. In case of any disease in apple tree leaves, farmers have to get support from expert agricultural personnel in order to detect the signs of disease at an early stage. This situation creates a great cost to the farmers. In order to solve the aforementioned problem, a deep learning model based on the Convolutional Neural Network (CNN) method has been developed to classify scab, rust and multiple disease groups in which both can be used together. The proposed approach consists of a combination of CNN layers using popular transfer learning techniques DenseNet201, MobileNetV2, ResNet50V2, ResNet101V2, ResNet152V2 algorithms as input layer. The developed method has been tested on a data set with high difficulty level, which includes different levels of illumination, noise, and heterogeneous illumination. With the CNN-based method recommended in the test processes, the classification accuracy rate was 97%.

Keywords: CNN, apple leaf disease, classification, transfer learning

1. Giriş

Günümüzde nüfusun hızlı artışı, su ve toprak kaynaklarının sürekli olarak kullanılması ve buna bağlı olarak artan kimyasal tarım gübre ve zirai ilaç tüketimi kirliliği artırmıştır. Bunlara ek olarak tarımda zararlı böcekler ile mücadele adına yapılan aşırı gübreleme ve bilinçsiz tarım ilacı kullanımı

* e-posta: halitcetiner@isparta.edu.tr ORCID ID: <https://orcid.org/0000-0001-7794-2555> (Sorumlu Yazar)

yakın su kaynaklarının doğasına zarar vermektedir. Bunların sonucunda toprak kirliliği, sudan içen hayvanların zehirlenmesi ve insan sağlığı üzerinde olumsuz bir etki oluşturmaktadır. Aynı zamanda bu etkilerden dolayı meyve üretimi çok büyük oranlarda zarar görmektedir. Bu gibi çeşitli faktörlerin sonucunda üretimde verim kaybı yaşanmakta ve tarım endüstrisindeki dengenin bozulmasına sebep olmaktadır. Bu sebeplerden dolayı tarım ürünlerindeki hastalıkların hızlı, ucuz, otomatik ve en doğru bir şekilde tanımlanması için görüntü işleme ve makine öğrenme teknikleri ile oluşturulacak yeni çözümlere ihtiyaç vardır.

Elma Türkiye’de Kayseri ve Isparta başta olmak üzere çok farklı şehirlerde yetiştirilebilen ve uzun süre çevresel şartlardan çok fazla etkilenmeden kalabilen bir meyvedir. Dünya genelinde ise 2018 yılında muz ve karpuzdan sonra en çok üretilen meyve türüdür ve yaklaşık olarak 86 milyon ton üretilmiştir [1]. Bu rakamlar potansiyel elma verimine göre azdır. Bunun da ana sebeplerinden bazıları; bitkisel hastalıklar, böcek haşereleri, üretim esnasında teknoloji kullanılmamasıdır. Belirtilen problemlerin önüne geçmek, üretim maliyetlerini düşürmekle beraber sürekli oluşan çevre kirliliğini de azaltacaktır.

Literatürde elma, bağışıklık sistemini geliştiren biyoaktif bileşenlerin kaynağı olarak görülmektedir [2]. Elmanın insan sağlığı üzerinde çok fazla faydasının olmasının yanında, bu meyvenin kendisi mikroorganizma ya da bakteriyel hastalıklara karşı oldukça hassastır. Bu durum beslenmede kullanılan farklı meyve ve sebze türleri içinde geçerlidir. Dünya çapında her yıl tarımsal üretimin yaklaşık olarak %42’si çeşitli mikroorganizmalar ve bitkisel hastalıklar neticesinden kullanılmadan çöpe gitmektedir [3]. Bu anlamda bitkilerin ve ürünlerin hastalıklardan korunması için ağaçların belirli zamanlarda gübrelenmesi ve ilaçlanması önemli bir noktadır.

Gübreleme işlemine rağmen yapraklarda değişim meydana geldiğinde çiftçiler tanı koyma konusunda problemler yaşayabilmektedir. Bunun yanında teknoloji kullanmayan çiftçiler, ürünleri ilaçlama noktasında uygun zamanı da kaçırabilmektedir. Hatalı ya da zamanında yapılmayan tedavi yaprak hastalıklarının hızlı bir şekilde yayılmasına neden olmaktadır. Özellikle patojen tarzı virüsler kısa zamanda çoğalmasından dolayı böcek hasarları ve hastalıklarda büyük artış göstermektedir. Bunların yanı sıra olası yanlış teşhis durumunda kimyasallar fazla veya yetersiz kullanımıyla çevresel zararlar ve maliyetler de artış görülmektedir [4]. Böyle bir durumda da uzman tarım personeline ihtiyaç duymaktadır. Özellikle kırsal kesimde küçük kapsamda üretim yapan çiftçiler çoğu zaman bahse konu olan uzman personele ulaşamamaktadır. Tasarlanan sistem ile hastalıklara üreticiler de tanı koyabilecektir. Böylece hastalıklardan en az seviyede etkilenerek verim artışı da sağlanabilecektir. Buna ek olarak uzman personel ihtiyacını da kısmen karşılamış olacaktır.

Bitki hastalığına bağlı çevresel, sosyal ve ekonomik açılardan meydana gelen kayıpları ortadan kaldırmak için bitki hastalıklarının önceden tespit edilmesi gerekmektedir. Geleneksel olarak bu önleme işlemleri ziraat mühendisleri tarafından yapılmasına rağmen zaman kaybı, verimsizlik ve büyük bir maliyet doğurmasından dolayı farklı yöntemler araştırılmaktadır [5]–[7]. Son zamanlarda derin öğrenme, görüntü işleme ve nesne tanıma alanlarında yapılan çalışmalar bu tür hastalıkların tespit edilmesi için uzmanlara yardımcı araçların geliştirilebileceğini göstermektedir. Elma hem Dünya genelinde hem de Türkiye’de çok fazla üretilen bir meyvedir. Bu makale kapsamında belirtilen problemlere çözüm, elma yaprak hastalıklarının otomatik sınıflandırılmasında aranmıştır. *Venturia Inaequalis* gibi farklı hastalıklar elma yapraklarında sıklıkla görülmektedir [8]. Bu hastalıkların oluşturduğu beneklerden dolayı elma üretiminde farklı oranlarda verim kaybı yaşamaktadır. Bunlara ek olarak son zamanlarda seller, yangınlar ile kendini daha fazla hissettiren küresel ısınma gibi sebeplerden dolayı hastalık daha hızlı yayılmakta ve yeni enfeksiyonlara neden olmaktadır. Tüm bu sebeplerin çözüme kavuşabilmesi için hastalıkların erken dönemde hızlı bir biçimde otomatik olarak tespit edilip sınıflandırılması önemlidir. Elma yapraklarında görülen genel hastalıklardan bazıları kahverengi ve sarı lekeler gibi farklı semptomlar meydana gelmektedir. Sağlıklı bir elma yaprak görüntüsüne göre meydana gelen farklılıklara odaklanarak sınıflandırma işlemi yapılmaktadır.

Günümüzde bitki hastalıkların tespiti için daha zahmetli ve daha fazla zaman alan çıplak göz ile tanı koyma işlemi, tespit sürecini yavaşlatmaktadır. Geçmişte kullanılan klasik yöntemler ile hastalık teşhisi yapmak çok fazla zaman ve emek almaktadır. Günümüz şartlarında bile hastalık tanısı genellikle

aynı yöntem ile konulmaktadır. Binlerce ağacın bulunduğu tarım arazilerinde ise daha büyük probleme neden olabilmektedir. Sonuç olarak teknolojik sistemlerin eksikliği meyve kalitesinin düşmesine sebep olmaktadır. Bu nedenle çiftçilere yardımcı olabilecek karar destek sistemlerinin geliştirilmesi önem arz etmektedir. Son yıllarda literatürde çeşitli bitkilere ait yaprak hastalıklarının sınıflandırılmasında kullanılan farklı makine öğrenme ve görüntü işleme algoritmaları bulunmaktadır [3], [9]–[11]. CNN yöntemleri ile bitkilerdeki en ayırt edici öznelikleri elde etme konusunda umut verici gelişmeler yaşanmaktadır. Bu gelişmelerde genellikle ince ayarlama yapılmış transfer öğrenme [12]–[15] yöntemleri kullanılmıştır. Bu çalışma kapsamında da CNN modelinin oluşturulmasında ayrı ayrı 4 farklı önceden eğitilmiş transfer modeli kullanılmıştır. Her birisinden elde edilen sonuçlar doğruluk ve kayıp bilgilerine göre karşılaştırmalı sunulmuştur.

Literatürdeki çalışmalar yeniden eskiye doğru incelendiğinde, büyük bir çoğunluğunda klasik makine öğrenme algoritmalarının kullanıldığı görülmektedir [9], [10], [16]. Bu çalışmalardan dikkat çeken bazıları; Sujatha vd. turunçgiller üzerinde bitki hastalıklarını tespit etmek için makine öğrenme algoritmalarını kullanmıştır [17]. Benzer bir çalışmada Yun vd. salatalık bitkisine ait yaprak görüntülerini olasılık tabanlı sinir ağı ile sınıflandırmaya çalışmıştır [18]. Literatürdeki başka bir çalışmada ise patates ve mısır bitkilerine ait yaprak hastalıklarının tanımlanabilmesi için bir sistem geliştirilmiştir [19]. Mevcut çalışmalar incelendiğinde üründe veya yaprağında bozulma meydana gelen bölgeden elde edilen istatistiksel öznelıklar kullanılmaktadır. Bunun yanında çalışmalarda kullanılan görüntülerde segmentasyon işlemide gerçekleştirilmiştir.

Klasik görüntü işleme yöntemlerinde kararlı sonuçlar alınabilmesi için eğitim örneklerinin yeterli sayıda olması gerekmektedir [20]. Bu tür yöntemlerin kullanılması esnasında aydınlıkta, parlaklık, kontrast düzensizlikleri, kusurlu lezyon alanı ile normal alan arasındaki benzerlikler gibi çeşitli faktörler sorun teşkil edebilmektedir. Son zamanlarda bu sorunların üstesinden gelebilecek, önceden eğitilmiş sinir ağı yöntemleri geliştirilmiştir. Bu yöntemlerde kullanılan konvolüsyon tabanlı yaklaşım ile yaprak hastalıklarının ve zararlılarının tespit edilmesinde klasik yöntemlere göre çok önemli öznelıklar otomatik olarak elde edilebilmektedir [21]. Yukarıdaki tespitleri baz alarak yapılan çalışmada elde edilen ana katkılar aşağıda maddeler halinde sunulmuştur.

- ResNet152V2, DenseNet201, MobileNetV2, ResNet50V2 önceden eğitilmiş ağ modelleri yardımıyla ön işlemde geçirilmiş bitki hastalık görüntülerinden girdi katmanı elde edilmiştir. Kullanılan yöntemlerden hangisinin yaprak hastalığının türünü belirlemede iyi olduğunu belirlemek için eklenen model ile ayrı ayrı performans analizi yapılmış ve sonuçları Tablo 2’de sunulmuştur.
- Önerilen temel bir konvolüsyonel sinir ağı (CNN) modeli ile de test görüntülerini tahmin edebilecek bir model önerilmiştir.
- Gerçekleştirilen çalışma ile hem üreticilere yardımcı bir karar destek sistemi geliştirilmiş hem de son yıllarda popüler olan derin öğrenme uygulamalarına ait önceden eğitilmiş farklı transfer öğrenme yöntemlerinin performans analizleri sunulmuştur.
- Tarım sektöründe erken teşhisin yaygınlaşması ile elma üretiminin artması beklenmektedir.

Makalenin geri kalan bölümü aşağıdaki şekilde planlanmıştır. Literatür özetinde çalışma konusu ile ilgili benzer çalışmalar incelenmiştir. Materyal ve Metod bölümünde kullanılan veri seti ve yöntemler hakkında bilgi verilmiştir. Geliştirilen model bölümünde ise sunulan model detaylı bir şekilde anlatılmış ve sonuçları paylaşılmıştır. En son bölüm olan Sonuç bölümünde ise çalışmadan elde edilen sonuçlar detaylandırılmıştır.

2. Literatür özeti

Literatürdeki çalışmalar incelendiğinde ImageNet, CoCoNet vb. önceden eğitilmiş ağ yapılarının içerisinde 1000 adet farklı sınıfa ait görüntülerin bulunduğu görülmüştür. Bitki hastalıklarında bu sınıflar içerisine entegre ederek sınıflandırabilecek bir sistemin tasarımı mümkündür [15]. Genel olarak

yapay zeka yöntemleri ve önceden eğitilmiş ağlar ince ayarlar yapılarak eğitimden sağlığa [22], enerjiden [23] hayvancılığa [24] kadar farklı birçok alana uygulanabilmektedir. Transfer öğrenme olarak tanımlanan bu yapılar, derin bir modelin öznitelik çıkarıcısı olarak kullanılmaktadır. Literatürde bitki hastalıklarının sınıflandırılmasında, transfer öğrenme yaklaşımının tüm ağırlıklarının sıfırdan öğrenildiği öğrenme yaklaşımlarına göre daha doğru sonuçlar verdiği tespit edilmiştir [14], [15]. Transfer öğrenme çalışmalarının çoğu ImageNet veri seti baz alarak geliştirilen önceden eğitilmiş modellere dayanmaktadır [13]. Genellikle ImageNet ağırlıklarını kullanan transfer öğrenme teknikleri, bu çalışmada olduğu gibi veri seti daha az görüntüden ve sınıftan oluşan durumlarda bile daha doğru modeller oluşturmaya olanak vermektedir. Buna ek olarak kontrollü koşullar altında sağlanan veri setlerinde de ince ayarlamalar yapılarak iyi sonuçlar verdiği görülmektedir [25]. Bu çalışmada kullanılan veri seti, ImageNet veri seti ağırlıkları kullanılarak modelin girdi katmanı oluşturulmuştur. Sonrasında diğer katmanların eklenmesi ile elde edilen modeller üzerinde yapılan ince ayarlar ve eklenen katmanlar ile sınıflandırma doğruluk oranları artırılmaya çalışılmıştır. Literatürde var olan çalışmalar incelendiğinde bitki lezyonlarına ait renk, doku, şekil, biçim gibi öznitelikler kullanılarak bitki hastalıklarının tespiti gerçekleştirilmiştir [5], [26], [27]. Bu çalışmalardan esinlenerek derin öğrenme algoritmalarında kullanılacak görüntüler bazı aşamalardan geçirilmektedir. İlk aşamada çalışmada kullanılacak görüntü sayısını arttırmak için görüntüler çevrilerek, yakınlaştırılıp uzaklaştırılarak görüntü sayısı arttırılmaktadır. Sonrasında da klasik görüntü ön işleme adımları uygulanmaktadır.

Dubey vd. şekil, doku, renk gibi farklı görüntü öznitelikleri kullanarak elma hastalıklarını sınıflandırmak için bir uygulama geliştirmiştir [28]. Geliştirdiği uygulamada K ortalamalar algoritması yardımıyla lezyon oluşan bölgeyi tespit etmiştir. Sonrasında tespit ettiği bölgeyi tanımlayan istatistiksel öznitelikleri tanımlayarak sınıflandırmıştır. Turkoglu vd. önceden eğitilmiş ağ modellerinden olan AlexNet, GoogleNet, DenseNet201 modelleri ile öznitelik elde edip LSTM yöntemi ile sınıflandıran bir model geliştirmiştir [8]. Wang vd. hastalık sebebiyle oluşan verim kaybını ölçebilmek adına hastalık şiddetini otomatik tahmin eden bir yapı tasarlamıştır [6]. Liang vd. ResNet tabanlı bir derin öğrenme yöntemi ile yaprak hastalığını sınıflandırmıştır [29]. Zhang vd. kırmızı, yeşil ve mavi renk kanallarını kullanarak üç kanallı konvolüsyonel bir sinir ağı oluşturmuştur. Bu sinir ağı modeli ile sebze yaprak hastalıklarını sınıflandırmıştır [30]. Tasarladığı yapıda en iyi sonucu VGG16 modeli ile elde etmiştir.

Çin’de yapılan bir çalışmada ise AlexNet transfer öğrenme modelinde yapılan ince ayarlamalar ile elma yaprak hastalıkları sınıflandırılmıştır [12]. Türkiye’de yapılan bir çalışmada ise yine endüstriyel otomasyon sisteminden elde edilen görüntüler üzerinden derin öğrenme modelleri ile sağlam ve çürük elma sınıflandırması gerçekleştirilmiştir [31]. Literatürdeki bir diğer çalışmada ise Ferentinos, farklı bitkilere ait sağlıklı ve hastalıklı görüntülerden oluşan bir verisetini kullanarak konvolüsyonlu bir sinir ağı modeli geliştirmiştir. Çalışmasında bitki hastalıklarındaki belirtilerin optik olarak gözlenmesindeki zorluklara da değinmektedir. Agronomistler, çiftlik teknisyenleri, ziraat mühendisleri, pazar bahçıvanları, ağaç yetiştiricileri ve bitki patoloğları tarafından bile genellikle bazı hastalıkların tipini, türünü belirlemede başarısız duruma düştükleri bahsedilmektedir. Bitki hastalıklarının tanısı ve teşhisinin otomatik olarak gerçekleştirilmesinin optik yöntemler ile tanı koymaya çalışan uzmanlar açısından büyük bir kolaylık sağlayacağı vurgulanmaktadır [32]. Yapılan çalışmalar incelendiğinde sahada çalışan uzmanlar tarafından, çıplak göz ile yaprak hastalık tespiti ve sınıflandırılmasının zor olduğu ifade edilmektedir [25].

3. Materyal ve Metod

3.1. Materyal

Bu çalışma kapsamında kullanılan veri setindeki görüntüler, farklı aydınlatma seviyesi ve açısı bulunan ortamlardan elde edilmiştir. Buna ek olarak görüntülerin arka planları da değişken yapıdadır. Veri setinde bir sağlıklı sınıf ve üç farklı hastalık sınıfına ait toplam 3642 adet yaprak görüntüleri bulunmaktadır. Veri seti içerisindeki farklı sınıflara ait yaprak görüntüleri dengeli olarak dağılmamaktadır. Veri setinin yüzde beşlik bir kısmında hem kabuklanma hastalığı hem de pas hastalığı

bulunmaktadır [4]. Veri setinde bahsedilen olumsuz durumlar görüntüler üzerinden hastalık analizini zorlaştırmaktadır. Kullanılan veri setinde healthy sınıfında 516, multiple diseases (MD) sınıfında 91, rust sınıfında 622, scab sınıfında 592 elma yaprak görüntüsü bulunmaktadır. Veri setindeki görüntüler 1821'şer adet eğitim ve test olarak ikiye ayrılmaktadır. Healthy sınıfına ait görüntüde herhangi bir hastalık işareti bulunmamaktadır. Bu görüntü lekesiz ve işaretsiz saf yeşilden oluşan sağlıklı yaprağı temsil etmektedir. Aynı şekilde MD ise aynı anda hem kabuklanma hem de paslanma hastalığı olan hastalık grubudur. Rust, yaprak üzerinde sarı şekillerin bulunduğu pas mantarından kaynaklanan hastalık grubudur. Son hastalık grubu olan Scab ise kahverengi yaralar ve izlerin bulunduğu mantardan meydana gelen hastalık grubunu temsil etmektedir. Bahsedilen hastalıklar Şekil 1'de gösterilmiştir.




Şekil 1. Veri setindeki sınıflardan örnek görüntüler ve toplam sayıları

Şekil 1'de gösterilen veri setinde bulunan yaprak görüntü örnekleri eğitim, test ve doğrulama gruplarına ayrılması gerekmektedir. Gruplara ayrıldıktan sonra veri çoğaltma işlemi gerçekleştirilmiştir. Eğitim veri setinde veri çoğaltma işlemi gerçekleştirilirken diğer gruplar üzerinde veri çoğaltma gerçekleştirilmemiştir.

3.2. Transfer öğrenme adımları

Derin öğrenme karmaşık ya da normal veri setlerinden en az ön işleme önemli özellikleri çıkartıp öğrenmeye odaklanan bir makine öğrenme alt yapısı olarak tanımlanmaktadır.



Şekil 2. Transfer öğrenme adımları

Klasik makine öğrenme algoritmalarına göre derin öğrenme algoritmaları farklı görüntü formatlarına doğrudan uygulanabilmektedir. Klasik makine öğrenme algoritmalarında var olan özellik çıkarma adımı derin öğrenme algoritmalarında tercihe bağlı olarak kendi içerisinde gerçekleştirilebilmektedir. Her iki algoritmada da görüntü boyutlandırma, gürültü temizleme, kenar belirleme, histogram eşitleme, ROI bölgesini belirleme adımları ortaktır. Şekil 2'de gösterilen adımlar, bu makale kapsamında oluşturulan modelin ilk aşaması olarak tanımlanmıştır.

Veri seti belirleme adımında zorluk derecesine bakılarak, arka planı homojen olmayan, aydınlatma durumu değişen, birden fazla hastalık bulunduran bir veri seti belirlenmiştir. İkinci adımda veri setinin orijinal halinde bulunan Eğitim ve Test verileri birleştirilerek tekrar %80'i eğitim, %10 doğrulama, %10 test verisi olacak şekilde ayrılmıştır. Şekil 2'de gösterilen ön işleme adımında eğitim görüntülerinin tamamı (224,224,3) boyutuna göre yeniden boyutlandırılmıştır. Belirtilen boyutlandırma önceden eğitilmiş ağ modellerine girdi sırasında işlem kolaylığı sağlamaktadır. Sonrasında bir diğer ön işleme adımı olarak veri çoğaltma tekniği uygulanmıştır. MD sınıfı gibi sayı olarak diğer sınıflardaki yaprak sayılarından az olması sebebiyle genelleştirme kabiliyeti düşüktür. Bu düşüklüğü ortadan kaldırabilmek için MD sınıfı başta olmak üzere görüntüleri iyileştirme, döndürme, ölçekleme ve çeviri ile veri sayısı az olan sınıf görüntülerinin genelleme kabiliyeti artırıldı. Bu işlemler Şekil 2'de gösterilen ön işlemler adımında gerçekleştirilmiştir. Ön işleme adımından sonra DenseNet201, MobileNetV2, ResNet50V2, ResNet101V2 ve ResNet152V2 transfer öğrenme teknikleri üzerinde ince ayarlamalar yapılmıştır. Bu makale kapsamında giriş ve çıkış katmanları revize edilerek kullanılan veri setine uygun hale getirilmiştir. Bu şekilde gerçekleştirilen öğrenme diğerlerine göre daha hızlıdır [25]. Öğrenmeyi hızlandırabilmek için ImageNet veri kümesi kullanılmıştır. Hastalık sınıflarının kategorisini belirlemek ve sınıflandırmak için ince ayar yapılmıştır. Şekil 2'de gösterilen modelde, ImageNet ile önceden eğitilmiş ağırlıklı modeller ayrı ayrı oluşturulmuştur. Modelde yapılan bir diğer ince ayarda ise RMSProp algoritması 0.0001'lik bir başlangıç öğrenme oranı kullanılmıştır. Şekil 2'de ince ayarlanmış modellerden elde edilen değerler, bundan sonraki aşamada sunulan ve çalışmaya özgü önerilen CNN modeline aktarılmıştır.

3.3. DenseNet201

Bu model Huang vd. [33] tarafından ağdaki katmanlar arasında maksimum bilgi aktarımını sağlamak için oluşturulmuştur. Her katman için önceki katmanlar girdi olarak kullanılır. Her katmanın öznelikleri sonraki katmanlara girdi olmaktadır. DenseNet ağ modelleri kaybolan gradyan problemini önemli ölçüde hafifletmektedir. Bunu gerçekleştirebilmek için model azaltılmış parametre sayısına sahiptir. Bunlara ek olarak DenseNet, önceki tüm katmanlar tarafından elde edilen öznelik haritalarını sonraki katmana girdi olarak vererek parametre verimliliği sağlamaktadır [34]. Parametre verimliliği ile ağlardaki derin katmanların önceki katmanlar tarafından üretilen tüm öznelik haritalarına erişmesi ve kullanması sağlanmaktadır. Bu durum l. katmandaki Xl öznelik haritası, diğerleri ise X0, ..., Xl-1 öznelik haritaları şeklinde Denklem 1 ile ifade edilebilir:

$$X_l = H_l([X_0, \dots, X_{l-1}]) \quad (1)$$

Denklem 1'de 0'ıncı katmandan l-1'inci katmana kadar ki öznelik haritası $[X_0, \dots, X_{l-1}]$ ile gösterilmiştir. H_l , toplu normalleştirme (BatchNormalization), Rectified linear units (ReLU) ve 3x3 konvolüsyon katmanlarının birleşmesinden oluşmaktadır.

Bu makale kapsamında yaprak hastalıklarını tanımlayabilmek için Denklem 1'i kullanan DenseNet201 yapısı oluşturuldu. Yapı ImageNet ile önceden eğitilmiş ağırlıklar ile yüklenmiştir. Sonrasında bu yapı, yaprak hastalıklarını sınıflandırmak için önerilen CNN modeline girdi olarak verilmiştir.

3.4. MobileNetV2

Mobil cihazların yaygınlaşması ile birlikte son zamanlarda geliştirilen tüm uygulamalar mobil ortamlarda çalışabilmektedir. Mobil ortamlar gibi taşınabilir bilgisayarlarda çalışabilen derin sinir ağı modellerinin en popüler olanlarından birisi MobileNetV2 mimarisidir. Hem mobil ortamda hem de diğer platformlarda çalışabilmesi bu mimariyi daha ön plana çıkarmaktadır.

Bu mimari, derinlemesine ayrılabilir konvolüsyon (depthwise separable convolution (DWSC)) yapısını kullanmaktadır. Çalışmada kullanılan bu mimari modelde ilk konvolüsyon 13 adet ayrılabilir konvolüsyon yapısını takip etmektedir. MobileNet mimarisinde her konvolüsyon yapısını bir toplu

normalleştirme ve ReLU aktivasyon fonksiyonu takip etmektedir. y adlı bir görüntüde normal bir konvolüsyon (NK) işlemini denklem ile ifade etmek istediğimizde;

$$NK(W, y)_{(i,j)} = \sum_{k=1}^{k=K} \sum_{l=1}^{l=L} \sum_{m=1}^{m=M} W(k, l, m) y(i + k, j + l, m) \quad (2)$$

Denklem 2 ifadesinde W ağırlıkları temsil etmektedir. $k=1$ den K değerine kadar görüntü genişliği, $l=1$ den L sütun değerine kadar görüntünün yüksekliği, i ve j değerleri görüntünün pozisyonlarını ve $m=1$ den M sayısına kadar filtreleri temsil etmektedir.

DWSC, iki adet derinlemesine konvolüsyon (depthwise convolution (DWC)) ve bir adet noktasal konvolüsyon (pointwise convolution (PWC)) yapısından oluşmaktadır. DWC yapısında görüntünün her renk kanalına, konvolüsyon filtreleri ve ağırlık matrisleri uygulanmaktadır.

$$DWSC(W_p, W_d, y)_{(i,j)} = PWC_{(i,j)} \left(W_p, DWC_{(i,j)}(W_d, y) \right) \quad (3)$$

$$DWC(W_d, y)_{(i,j)} = \sum_{k=1}^{k=K} \sum_{l=1}^{l=L} W_d(k, l) x y_{(i+k, j+l)} \quad (4)$$

$$PWC(W_p, y)_{(i,j)} = \sum_{m=1}^M W_m y_{(i,j,m)} \quad (5)$$

MobileNet mimari modellerini oluşturan DWSC, DWC ve PWC yapıları sırasıyla Denklem 3, 4 ve 5’de gösterilmiştir. Denklem 2 ifadesinde olduğu gibi K değerleri görüntü genişliğini temsil ederken, L değerleri görüntü yüksekliğini temsil etmektedir. i ve j değerleri de Denklem 2’de olduğu gibi burada da görüntü pozisyonları ifade etmektedir. DWC y görüntüsüne W_d ‘yi, PWC ise W_p ‘yi kullanmaktadır. PWC, DWC’nin çıktılarını birleştirebilmek için 1×1 konvolüsyon filtresi içermektedir. PWC’nin ana özneliği DWC’nin çıkış öznelik matris boyutlarını azaltmaktır. Denklem 5’de görüldüğü üzere PWC öznelik matrisi m sayıdaki filtreye doğrudan bağlıdır. W_m ise PWC yapısının ağırlık filtresi olarak tanımlanmaktadır.

Bu mimari diğer mimarilere göre daha düşük donanımsal özelliklere sahip cihazlar üzerinde çalışabilmektedir. Yapılan çalışma kapsamında performans değerlendirmesine tabi tutulan diğer mimarilerden daha az hesaplama maliyetine sahiptir. Diğer mimari yapılarda olduğu gibi bu mimari yapıda da ImageNet ağırlıkları kullanılmıştır. Sonrasında oluşturulan yapı, yaprak hastalıklarını sınıflandırmak için önerilen CNN modeline girdi olarak verilmiştir.

3.5. ResNet

He vd. [35] tarafından ortaya çıkartılan ResNet, konvolüsyon ve havuzlama katmanlarından oluşan blok yapılarından oluşmaktadır. Bu mimari VGG mimarisine benzemekle birlikte VGG ağlarından çok daha fazla derindir. Tam bağlantılı katmanlar yerine genel olarak ortalama havuzlama yapıları kullanılmaktadır. 50, 101 ve 152 katmanlardan oluşan ResNet mimarileri bulunmaktadır.

ResNet mimarilerinde katmanları atlayan kısayal bağlantıları bulunan Residual Building Block (RBB) yapıları bulunmaktadır [36]. Bu yapılar sayesinde optimizasyon amaçlı yerel optimum noktalarına takılma sorunu çözülmektedir. RBB yapıları bu kısayol bağlantılarına ek olarak konvolüsyon, toplu normalleştirme, ReLU katmanlarından oluşmaktadır. RBB yapılarının ise RBB-1 ve RBB-2 olmak üzere iki farklı yapısı bulunmaktadır. RBB-1 yapısında kısayollar x , doğrusal olmayan fonksiyon F ile gösterilmiştir. Belirtilen parametreler ile RBB-1’in çıkışını gösteren y ise Denklem 6’da gösterilmiştir.

$$y = F(x) + x \quad (6)$$

RBB-2 yapısında ise RBB-1 yapısı üzerine bir adet konvolüsyon ve toplu normalleştirme katmanı daha eklenmiştir. Birlikte eklenen bu katmanlar H ile ifade edilirse Denklem 7 oluşmaktadır.

$$y = F(x) + H(x) \quad (7)$$

Bu makale kapsamında yaprak hastalıklarını tanımlayabilmek için ResNet50V2, ResNet101V2, ResNet152V2 yapıları oluşturulmuştur. Oluşturulan bu yapılar ImageNet veri setini kullanarak ağırlıklar ile yüklenmiştir. Sonrasında bu yapılar, yaprak hastalıklarını sınıflandırmak için önerilen CNN modeline girdi olarak verilmiştir.

4. Geliştirilen Model

Transfer öğrenme mimarilerinde giriş, tam bağlantı ve sınıflandırma katmanlarında yapılan ince ayarlamalar ile bu mimarilerin eğitildiği veri seti dışında farklı veri setlerinede uygulanabilmesi mümkündür. Önceden eğitilmiş ağlardan farklı bir veri setinde kullanımında öznelik çıkarma işlemi uygulanabildiği gibi oluşturulan bir CNN modeline girdi katmanı olarak yerleştirilebilmektedir. Bunun için önceden eğitilmiş ağlarda değişiklik yapılması gereken katmanlar ile birlikte ağın tüm katmanlarının yeni görüntü üzerinde çalıştırılmasını gerekmektedir.

Burada;

- Önceden eğitilmiş bir ağ alınmaktadır. Çıkış katmanı kaldırılmaktadır. Giriş katmanı bu çalışmada kullanılan veri setine göre ince ayarlardan geçirilmektedir.
- Önceden eğitilmiş ağın üstüne yeni bir CNN mimarisi eklenmekte ve sonrasında bir sınıflandırma eklenmektedir.
- Sonrasında, bu ince ayarlar ile birlikte hem doğrulama hem eğitim verileri ile ağ modeli oluşturulmaktadır.
- Son olarak test görüntüleri modele verildiğinde tanıma işlemi kolaylıkla yapılabilmektedir.

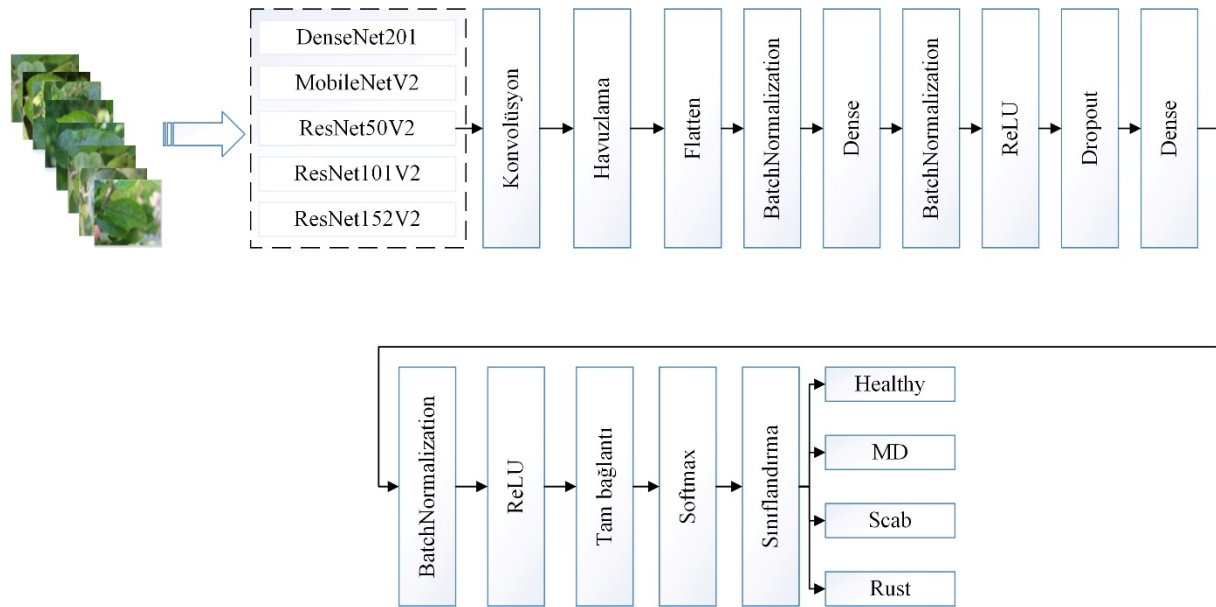
CNN tabanlı sınıflandırma modeli Şekil 3’de gösterilmiştir. Şekil 2’de CNN tabanlı modülün ilk katmanını oluşturan transfer öğrenim çıktıları elde edilmiştir. Bu çalışma kapsamında kullanılan DenseNet201, MobileNetV2, ResNet50V2, ResNet101V2 ve ResNet152V2 önceden eğitilmiş, ince ayarlı CNN algoritmaları genel olarak giriş katmanına katman olarak eklenmiştir. Sonrasında önerilen modelin katman sıralaması şu şekilde planlanmıştır. 5x5’lik filtreler sahip konvolüsyon katmanı, maksimum havuzlama, düzleştirme (Flatten) katmanı, toplu normalleştirme, 2048 çıkışlı tam bağlantı katmanı, toplu normalleştirme, ReLU aktivasyon, unutmaya (Dropout) katmanı, 1024 çıkışlı tam bağlantı katmanı, toplu normalleştirme, ReLU aktivasyon katmanı, unutmaya katmanı ve son olarak sınıf sayısına eşit sayıda çıkış değerine sahip softmax aktivasyon fonksiyonlu tam bağlantı katmanı eklenmiştir.

Tablo 1. Öznelik çıkarmada kullanılan ağ detayları

Ağ	Derinlik	Boyut (MB)	Parametre
DenseNet201 [33]	201	77	20.242.984
ResNet50V2 [35]	-	98	25.613.800
ResNet101V2 [35]	-	171	44.675.560
ResNet152V2 [35]	-	232	60.380.648
MobileNetV2 [37]	88	14	3.538.984

Giriş katmanı ağa verilen girdilerin verildiği katmandır. Bu katmanda girdi boyutunun önceden ayarlanması gerekmektedir. Bu çalışma boyunca girdiler (224,224) genişlik ve yükseklik boyutunda ayarlanmıştır. Renk kanalı olarak RGB renk kanalı kullanılmış. Girdi sağlamadan temel anlamda görüntüler ön işleminden geçmiştir. Konvolüsyon katmanı, görüntüdeki piksel matrislerini kullanarak öznelik matrisini elde eden temel katmandır. Bu katman görüntü üzerinde belirli filtreleri dönüştürmektedir. Filtreler farklı boyutlarda tanımlı olabilmektedir. En sık kullanılan bu boyutlara örnek olarak 3x3, 5x5, 7x7, 9x9 veya 11x11 verilebilir.

Çalışmada 60 adet 5×5 'lik filtrelelere sahip konvolüsyon katmanı oluşturulmuştur. ReLU katmanı, aslında aktivasyon katmanıdır. Aktivasyon katmanı konvolüsyon katmanından sonra gelmektedir. Doğrusal ve doğrusal olmayan dönüşüm işlemlerinde kullanılmaktadır. Gerçek veriyi ağına anlayabileceği aralık ve formata getirmektedir. Havuzlama katmanı, konvolüsyon ve ReLU işlemlerinden sonra gerçekleştirilmektedir. Hafızaya dokunmadan görüntü boyutunu azaltmaya çalışmaktadır. Havuzlama katmanında genel olarak maksimum filtreleme ya da ortalama filtreleme kullanılmaktadır. Tam bağlantılı katman ise konvolüsyon, ReLU ve havuzlama katmanından sonra gelmektedir. Bu katmandan önceki öznelik çıkarma nöronları ile tam bağlantı halindedir. Unutma katmanı ağıdaki bazı nöronları aşırı öğrenmenin önüne geçebilmek adına silmektedir. Rastgele seçilen bazı nöronlar ihmal edilebilmektedir. Sınıflandırma katmanı, adından da anlaşılabilir gibi sınıflandırma girdilere göre sınıf etiketlerinin elde edilmesini sağlar. Sınıf etiketlerin elde edilmesinde softmax fonksiyonunu kullanılmaktadır. Tablo 1'de bu çalışma kapsamında kullanılan önceden eğitilmiş ağların detay özellikleri verilmiştir.



Şekil 3. Önerilen CNN tabanlı elma yaprak hastalığı sınıflandırma modeli

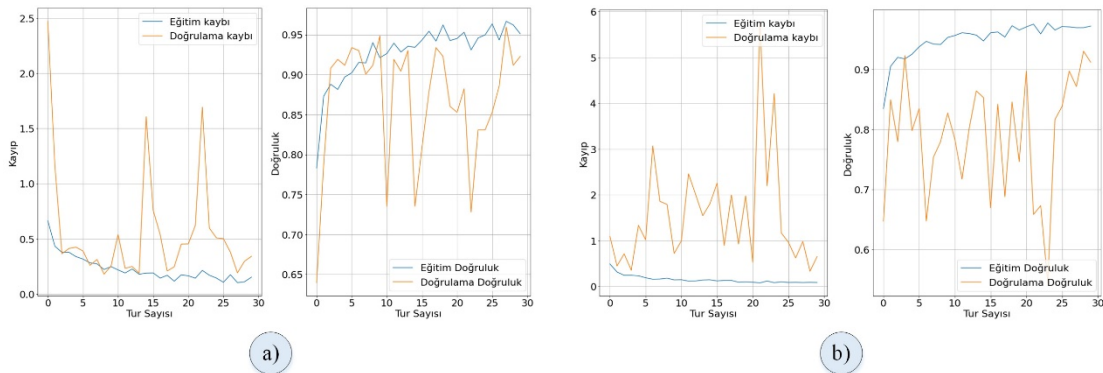
DenseNet201, ResNet50V2, ResNet101V2, ResNet152V2 ve MobileNetV2 mimarileri üzerinde yapılan farklı katmanlardaki ince ayar ile oluşturulan yeni modele katman olarak verilmiştir. Sonrasında önerilen modele ait yukarıda ayrıntıları verilen katmanlar sırasıyla yerleştirilmiştir. Katmanlar ardı sıra boyutları birbirine uyacak şekilde sıralaması belirlenmiştir. Son aşamada ise tam bağlantı katmanı ile her bir nöron tüm öznelik haritası ile bağlantı sağlanmaktadır. Bu bağlantılar, Softmax aktivasyon fonksiyonunu baz alarak sınıf puanlamalarını belirlemektedir. Sınıflandırma katmanı ise sınıflandırıcı görevi için özelleşmektedir. Elma yaprak hastalıklarını sınıflandırmak için farklı deneysel çalışmalar sonucunda Şekil 3'de belirtilen CNN algoritması oluşturulmuştur.

4.1. Deneysel Sonuçlar


İnce ayarlamalarda, adım değerleri gibi tüm değerlerin, transfer öğrenme yapılmak istenen tüm mimarilerde aynı olacak şekilde değer atamaları yapılmıştır. Buna ek olarak eğitim, doğrulama ve test verileri K-fold 10 değerine ayrılmıştır. Bu nedenle çalışmada K-fold10 değerine göre elde edilen performans değerlerini ortalaması sunulmuştur. Yapılan eğitim işlemlerinde elde edilen sonuçlarda DenseNet201 diğer modellerden daha başarılı bir sonuç vermiştir. Bu sonuçlar ve sıradan modellere göre önerilen modellerin verdiği başarı oranları Tablo 2'te sunulmuştur. F1, Hassasiyet, Eğitim doğruluk ve doğrulama doğruluk değerleri birbirine yakın çıkmıştır.

Tablo 2. Kullanılan transfer öğrenimine göre önerilen CNN algoritmanın sınıflandırma sonuçları

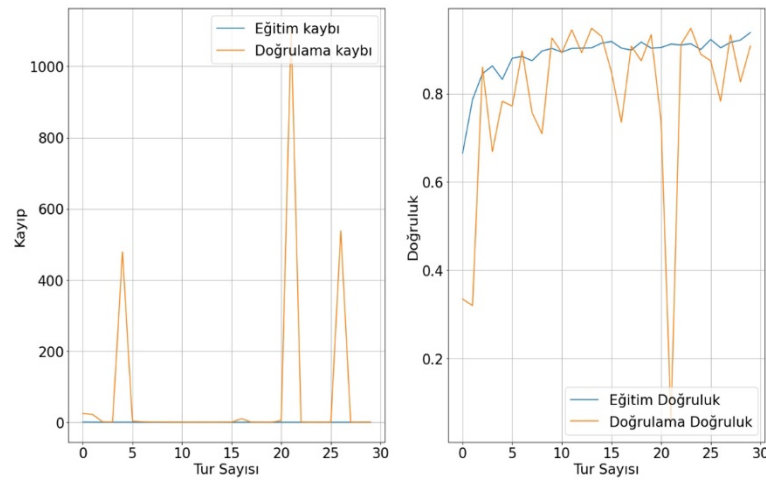
Transfer öğrenme	Eğitim doğruluk	Doğrulama doğruluk	F1 puan	Hassasiyet
Önerilen DenseNet201	0.96	0.95	0.95	0.96
Önerilen ResNet50V2	0.94	0.95	0.94	0.95
Önerilen ResNet101V2	0.93	0.94	0.93	0.93
Önerilen ResNet152V2	0.94	0.95	0.93	0.94
Önerilen MobileNetV2	0.97	0.93	0.94	0.93
DenseNet201	0.94	0.92	0.93	0.92
ResNet50V2	0.91	0.92	0.91	0.91
ResNet101V2	0.92	0.91	0.92	0.91
ResNet152V2	0.93	0.93	0.92	0.91
MobileNetV2	0.95	0.90	0.92	0.92

**Şekil 4.** a) Önerilen CNN algoritmasının DenseNet201 için eğitim ve doğrulama kaybı ve doğruluk grafikleri, b) Önerilen CNN algoritmasının MobileNetV2 için eğitim ve doğrulama kaybı ve doğruluk grafikleri

Şekil 4'te önerilen CNN yöntemiyle aynı ince ayarlamalara tabi tutulan DenseNet201 ve MobileNetV2 transfer öğrenim teknikleri ile elde edilen eğitim ve doğrulama kayıp ve doğruluk grafikleri sunulmuştur. Şekil 5'te önerilen CNN yöntemiyle aynı ince ayarlamalara tabi tutulan ResNet50V2 ve ResNet101V2 transfer öğrenim teknikleri ile elde edilen eğitim ve doğrulama kayıp ve doğruluk grafikleri gösterilmiştir. Şekil 6'da önerilen CNN yöntemiyle aynı ince ayarlamalara tabi tutulan ResNet152V2 transfer öğrenim tekniği ile elde edilen eğitim ve doğrulama kayıp ve doğruluk grafikleri gösterilmiştir. Elde edilen sonuçlar incelendiğine doğrulama grafiklerinde bir dalgalanma görülmektedir. Bunun ana sebebi olarak görülebilecek eğitim ve doğrulama verilerinin dağılımı düşünülebilir. Ancak veri dağılımı rastgele olacak şekilde yapılmıştır. Veri çoğaltma tekniğinde sınıflar arası veri dengesizliğinin giderilebilmesi için veri çoğaltma tekniği uygulanmıştır. Veri çoğaltma tekniğinde MD sınıfına özel veri çoğaltma yapılarak veri sayısı diğer sınıflardan en yüksek veri sayısına sahip sınıfın sayısına getirilmiştir. Şekil 4, Şekil 5 ve Şekil 6 birlikte incelendiğinde eğitim doğruluklarının genel olarak doğrulama doğruluk değerlerinden daha yüksek olduğu görülmektedir.



Şekil 5. a) Önerilen CNN algoritmasının ResNet50V2 için eğitim ve doğrulama kaybı ve doğruluk grafikleri, b) Önerilen CNN algoritmasının ResNet101V2 için eğitim ve doğrulama kaybı ve doğruluk grafikleri




Şekil 6. Önerilen CNN algoritmasının ResNet152V2 için eğitim ve doğrulama kaybı ve doğruluk grafikleri

Bu çalışma kapsamında geliştirilen modeller ile karşılaştırma tablosu hazırlanmıştır. Tablo 3 aynı verisetini kullanan iki farklı çalışma ile yapılan doğruluk karşılaştırılmasını göstermektedir. Önerilen yaklaşım iki farklı çalışmadan da daha iyi doğruluk oranı vermiştir. Bansal et al. [38] çalışmasında DenseNet121, EfficientNetB7 ve EfficientNet NoisyStudent modellerini kullanarak bir method oluşturduğunu bildirmektedir. Belirtilen önceden eğitilmiş algoritmalarından faydalanarak bitki hastalığı varsa hızlı bir şekilde tespit etmeye çalışmıştır. Divakar et al. [39] ise SMOTE yöntemi kullanılarak elde edilmiş dengeli bir veri setinde EfficientNetB7 yöntemi ile sınıflandırma gerçekleştirmiştir. Yöntemde farklı önceden eğitilmiş modeller kullanılmasına rağmen en başarılı sonuçların EfficientNetB7 yönteminde elde edildiğini bahsetmektedir.

Tablo 3. Aynı veri setini kullanan literatürdeki çalışmalarla karşılaştırma sonuçları

Model	Yıl	Yöntem	Doğruluk
Bansal et al. [38]	2021	Derin konvolüsyonel sinir ağı	0.96
Divakar et al. [39]	2021	Smote-DL	0.91
Proposed model	2021	Konvolüsyonel sinir ağı yaklaşımı	0.97

Önerilen mimari model oluşturulduktan sonra, test işlemlerinde kullanılmaya hazır hale getirilmiştir. Test veri setindeki görüntüler, eğitilen modele girdi olarak verilmiştir. Girdi sonucunda elde edilen sonuç softmax fonksiyonuna sokularak sınıf puanları elde edilmiştir. Elde edilen sınıf puanlarından maksimum olanı tahmin edilen sınıf etiketi olarak atanmıştır. Son olarak önerilen modelin tahmin ettiği sınıf etiketi ile gerçekteki sınıf etiketi karşılaştırılarak tahminin doğru olup olmadığına karar verilmektedir. Test veri setinden 4 farklı sınıfa ait bazı görüntülerde yapılan tahmin sonuçları Şekil 7’de gösterilmiştir.



Şekil 7. Test veri setindeki Test_2, Test_4, Test_31 ve Test_11 görüntülerinin test sonuçları

5. Sonuç

Bu çalışma kapsamında elma yaprak hastalıkları ön işlemlerden geçirilerek DenseNet121, MobileNetV2, ResNet50V2, ResNet101V2 ve ResNet152V2 transfer öğrenme teknikleri yardımıyla önerilen CNN yönteminin girdi katmanı oluşturulmuştur. Girdi katmanı üzerine tanıma ve sınıflandırma oranlarını artıracak şekilde temel sinir ağı katmanları eklenmiştir. Elde edilen çalışma sonucunda DenseNet201 ağından elde edilen eğitim doğruluk ve doğrulama doğruluk sonuçları diğer ağ modellerinden daha yüksektir.

Bundan sonraki çalışmada veri setinin aynı sınıfları içeren farklı veri setleri ile birleştirilerek kullanılması üzerine gerçek zamanlı bir çalışma yapılması planlanmaktadır. Doğrulama, doğruluk ve kayıplar arasındaki farklılıkların üzerine gidebilmek için orijinal verilerin artırılması gerekmektedir. Özellikle MD sınıfında az olan örnek sayısı problemin çözümünü zorlaştırmaktadır. Sınıflar arasındaki veri dağılımını dengeleyebilmek için MD sınıfı üzerinde daha fazla veri çoğaltma işlemi yapılması gerekmiştir. Bu işlem gerçekleştirildiğinde ise Şekil 4, 5 ve 6’da görüldüğü üzere farklı aşağı yukarı grafik hareketleri görülmektedir. Eğitim ve doğrulama arasındaki istatistiksel değer farklılıklarının kapanabilmesi için doğrulama verilerinin veri setini daha iyi temsil edebilecek görüntülerden seçilmesinin önem içerdiği kanısına varılmıştır.

Teşekkür

Bu çalışma kapsamında kullanılan veri setini hazırlayan [4] çalışmasına ait yazarlara teşekkür ederim.

Kaynaklar

- [1] G. Sottocornola, F. Stella, and M. Zanker, *Counterfactual Contextual Multi-Armed Bandit: a Real-World Application to Diagnose Apple Diseases*. 2021.
- [2] B. Duralija *et al.*, “The Perspective of Croatian Old Apple Cultivars in Extensive Farming for the Production of Functional Foods,” *Foods*, vol. 10, no. 4. 2021, doi: 10.3390/foods10040708.
- [3] M. Bin Tahir *et al.*, “Recognition of Apple Leaf Diseases using Deep Learning and Variances-Controlled Features Reduction,” *Microprocess. Microsyst.*, p. 104027, 2021, doi: <https://doi.org/10.1016/j.micpro.2021.104027>.
- [4] R. Thapa, K. Zhang, N. Snavely, S. Belongie, and A. Khan, “The Plant Pathology Challenge 2020 data set to classify foliar disease of apples,” *Appl. Plant Sci.*, vol. 8, no. 9, p. e11390, Sep. 2020, doi: <https://doi.org/10.1002/aps3.11390>.
- [5] V. Singh and A. K. Misra, “Detection of plant leaf diseases using image segmentation and soft computing techniques,” *Inf. Process. Agric.*, vol. 4, no. 1, pp. 41–49, 2017, doi: <https://doi.org/10.1016/j.inpa.2016.10.005>.
- [6] G. Wang, Y. Sun, and J. Wang, “Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning,” *Comput. Intell. Neurosci.*, vol. 2017, p. 2917536, 2017, doi: 10.1155/2017/2917536.
- [7] K. Kayaalp and S. Metlek, “Classification of Robust and Rotten Apples by Deep Learning Algorithm,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 3, no. 2, pp. 111–119, Aug. 2020, doi: 10.35377/saucis.03.02.717452.
- [8] M. Turkoglu, D. Hanbay, and A. Sengur, “Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests,” *J. Ambient Intell. Humaniz. Comput.*, 2019, doi: 10.1007/s12652-019-01591-w.
- [9] G. Shrivastava, “Review on Emerging Trends in Detection of Plant Diseases using Image Processing with Machine Learning,” *Int. J. Comput. Appl.*, vol. 174, Jan. 2021, doi: 10.5120/ijca2021920990.
- [10] N. Gobalakrishnan, K. Pradeep, C. J. Raman, L. J. Ali, and M. P. Gopinath, “A Systematic Review on Image Processing and Machine Learning Techniques for Detecting Plant Diseases,” in *2020 International Conference on Communication and Signal Processing (ICCSP)*, 2020, pp. 465–468, doi: 10.1109/ICCSP48568.2020.9182046.
- [11] A. Gargade and S. A. Khandekar, “A Review: Custard Apple Leaf Parameter Analysis and Leaf Disease Detection using Digital Image Processing,” in *2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)*, 2019, pp. 267–271, doi: 10.1109/ICCMC.2019.8819867.
- [12] B. Liu, Y. Zhang, D. He, and Y. Li, “Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks,” *Symmetry (Basel)*, vol. 10, no. 1, p. 11, 2018, doi: <http://dx.doi.org/10.3390/sym10010011>.
- [13] O. Russakovsky *et al.*, “ImageNet Large Scale Visual Recognition Challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, 2015, doi: 10.1007/s11263-015-0816-y.
- [14] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, “A comparative study of fine-tuning deep learning models for plant disease identification,” *Comput. Electron. Agric.*, vol. 161, pp. 272–279, 2019, doi: <https://doi.org/10.1016/j.compag.2018.03.032>.
- [15] S. H. Lee, H. Goëau, P. Bonnet, and A. Joly, “New perspectives on plant disease characterization based on deep learning,” *Comput. Electron. Agric.*, vol. 170, p. 105220, 2020, doi: <https://doi.org/10.1016/j.compag.2020.105220>.
- [16] L. S. P. Annabel, T. Annapoorani, and P. Deepalakshmi, “Machine Learning for Plant Leaf Disease Detection and Classification – A Review,” in *2019 International Conference on Communication and Signal Processing (ICCSP)*, 2019, pp. 538–542, doi: 10.1109/ICCSP.2019.8698004.
- [17] R. Sujatha, J. M. Chatterjee, N. Z. Jhanjhi, and S. N. Brohi, “Performance of deep learning vs machine learning in plant leaf disease detection,” *Microprocess. Microsyst.*, vol. 80, p. 103615, 2021, doi: <https://doi.org/10.1016/j.micpro.2020.103615>.

- [18] Y. Shi, X. F. Wang, S. W. Zhang, and C. L. Zhang, "PNN based crop disease recognition with leaf image features and meteorological data," *Int. J. Agric. Biol. Eng.*, vol. 8, pp. 60–68, Aug. 2015, doi: 10.3965/j.ijabe.20150804.1719.
- [19] K. Aurangzeb, F. Akmal, M. A. Khan, M. Sharif, and M. Y. Javed, "Advanced Machine Learning Algorithm Based System for Crops Leaf Diseases Recognition," in *2020 6th Conference on Data Science and Machine Learning Applications (CDMA)*, 2020, pp. 146–151, doi: 10.1109/CDMA47397.2020.00031.
- [20] M. A. Khan, T. Akram, M. Sharif, and T. Saba, "Fruits diseases classification: exploiting a hierarchical framework for deep features fusion and selection," *Multimed. Tools Appl.*, vol. 79, no. 35, pp. 25763–25783, 2020, doi: 10.1007/s11042-020-09244-3.
- [21] X. Yang and T. Guo, "Machine learning in plant disease research," *Eur. J. Biomed. Res.*, vol. 3, p. 6, Mar. 2017, doi: 10.18088/ejbmr.3.1.2017.pp6-9.
- [22] S. Metlek and E. E. Kılınç, "Determination of Heart Disease By Machine Learning Methods," in *5th International Gap Mathematics-Engineering-Science and Health Sciences Congress*, 2020, pp. 48–74, doi: ISBN: 978-625-7687-23-2.
- [23] D. F. Mengi and S. Metlek, "Türkiye'nin Akdeniz Bölgesine ait rüzgâr ekserjisinin çok katmanlı yapay sinir ağı ile modellenmesi," *Int. J. Eng. Innov. Res.*, vol. 2, no. 2, pp. 102–120, 2020.
- [24] S. Metlek and K. Kayaalp, "Detection of bee diseases with a hybrid deep learning method," *J. Fac. Eng. Archit. Gazi Univ.*, vol. 36, no. 3, pp. 1716–1731, Mar. 2021, doi: 10.17341/gazimmfd.749443.
- [25] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using Deep Learning for Image-Based Plant Disease Detection," *Front. Plant Sci.*, vol. 7, p. 1419, 2016, doi: 10.3389/fpls.2016.01419.
- [26] K. Prashar, R. Talwar, and C. Kant, *Robust Automatic Cotton Crop Disease Recognition (ACDR) Method using the Hybrid Feature Descriptor with SVM*. 2017.
- [27] D. Tiwari, M. Ashish, N. Gangwar, A. Sharma, S. Patel, and S. Bhardwaj, *Potato Leaf Diseases Detection Using Deep Learning*. 2020.
- [28] S. R. Dubey and A. S. Jalal, "Apple disease classification using color, texture and shape features from images," *Signal, Image Video Process.*, vol. 10, no. 5, pp. 819–826, 2016, doi: 10.1007/s11760-015-0821-1.
- [29] Q. Liang, S. Xiang, Y. Hu, G. Coppola, D. Zhang, and W. Sun, "PD2SE-Net: Computer-assisted plant disease diagnosis and severity estimation network," *Comput. Electron. Agric.*, vol. 157, pp. 518–529, Feb. 2019, doi: 10.1016/j.compag.2019.01.034.
- [30] S. Zhang, W. Huang, and C. Zhang, "Three-channel convolutional neural networks for vegetable leaf disease recognition," *Cogn. Syst. Res.*, vol. 53, pp. 31–41, 2019, doi: <https://doi.org/10.1016/j.cogsys.2018.04.006>.
- [31] K. Kayaalp and S. Metlek, "Classification of Robust and Rotten Apples by Deep Learning Algorithm," *Sak. Univ. J. Comput. Inf. Sci.*, vol. 3, pp. 111–119, Aug. 2020, doi: 10.35377/saucis.03.02.717452.
- [32] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Comput. Electron. Agric.*, vol. 145, pp. 311–318, 2018, doi: <https://doi.org/10.1016/j.compag.2018.01.009>.
- [33] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700–4708.
- [34] X. Yu, N. Zeng, S. Liu, and Y.-D. Zhang, "Utilization of DenseNet201 for diagnosis of breast abnormality," *Mach. Vis. Appl.*, vol. 30, no. 7, pp. 1135–1144, 2019, doi: 10.1007/s00138-019-01042-8.
- [35] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jun. 2016, pp. 770–778, doi: 10.1109/CVPR.2016.90.
- [36] T. Liu, M. Chen, M. Zhou, S. S. Du, E. Zhou, and T. Zhao, "Towards understanding the importance of shortcut connections in residual networks," *arXiv Prepr. arXiv1909.04653*, 2019.
- [37] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted

- residuals and linear bottlenecks,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.
- [38] P. Bansal, R. Kumar, and S. Kumar, “Disease Detection in Apple Leaves Using Deep Convolutional Neural Network,” *Agriculture*, vol. 11, no. 7. 2021, doi: 10.3390/agriculture11070617.
- [39] S. Divakar, A. Bhattacharjee, and R. Priyadarshini, “Smote-DL: A Deep Learning Based Plant Disease Detection Method,” in *2021 6th International Conference for Convergence in Technology (I2CT)*, 2021, pp. 1–6, doi: 10.1109/I2CT51068.2021.9417920.