

(Araştırma Makalesi)**Transfer Öğrenme Modelleri ile Elma Yapraklarında Hastalık Tespiti**
Mihriban AYBAR¹, Uğur TALAŞ^{*2}, Burakhan ÇUBUKÇU³

¹Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 11100, Bilecik,
ORCID No : <http://orcid.org/0009-0009-2452-5382>

² Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 11100, Bilecik,
ORCID No : <http://orcid.org/0000-0002-9287-413X>

³ Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 11100, Bilecik,
ORCID No : <http://orcid.org/0000-0003-0480-1254>

Anahtar Kelimeler:

Transfer Öğrenme,
Xception,
InceptionV3,
PlantVillage

Özet: Bu çalışmada elma ağacı yapraklarının görüntüleri üzerinde transfer öğrenme yöntemleri kullanılarak hastalıkların teşhis edilebilmesi amaçlanmıştır. Birçok alanda olduğu gibi tarım alanında da verimlilik oldukça önemlidir. Verimliliği yüksek tutmanın önemli unsurlarından biri bitki hastalıklarıyla mücadele etmektir. Hastalıklarla mücadele edebilmek için hastalığın erken teşhis edilmesi, bu mücadeleyi kolaylaştırmaktadır. Elma ağaçlarında sıklıkla görülen “kara çürüklük”, “sedir elma pası” ve “elma kabuğu uyuz” hastalıkları için yaprak görüntülerinden uzman desteğiyle teşhis yapılabilmektedir. Bu çalışmada PlantVillage veri seti kullanılarak bu hastalıkların teşhisi için yapay zeka modelleri kullanılmıştır. Çalışmada Xception ve InceptionV3 transfer öğrenme yöntemleri kullanılarak, modeller popüler metrikler ile karşılaştırılarak incelenmiştir. Xception modeli ile %99,84 doğruluk oranı elde edilirken, InceptionV3 modeli ile %98,58 doğruluk oranına ulaşılmıştır.

(Research Article)**Disease Detection on Apple Leaves Using Transfer öğrenme Models****Keywords:**

Transfer Learning,
Xception,
InceptionV3,
PlantVillage

Abstract: In this study, the aim is to diagnose diseases on apple tree leaves using transfer öğrenme methods. As in many fields, efficiency is highly important in agriculture. One of the key factors in maintaining high efficiency is combating plant diseases. Early detection of diseases makes this struggle easier. Diseases such as 'black rot,' 'cedar apple rust,' and 'apple scab,' which are commonly seen in apple trees, can be diagnosed from leaf images with expert support. In this study, artificial intelligence models were used to diagnose these diseases using the PlantVillage dataset. Xception and InceptionV3 transfer öğrenme methods were employed, and the models were examined by comparing them with popular metrics. An accuracy rate of 99.84% was achieved with the Xception model, while the InceptionV3 model reached an accuracy rate of 98.58%.

1. GİRİŞ

Günümüzde insan nüfusunun artışı tüketimi artırırken tarımda çalışan insan nüfusunun azalmasıyla birlikte tarımdaki verimliliğin önemini artırmıştır. Tarımda verimliliği arttırmak için en önemli konulardan biri bitki hastalıklarıyla mücadele etmektir [1]. Bitkilerde hastalık belirtileri genellikle yapraklarda, meyvelerde, tomurcuklarda ve genç dallarda ortaya çıkar. Bu

hastalıklarla mücadele edilmediğinde meyvenin israf olmasına veya zarar görmesine sebep olur. Bu nedenle bitkilerde hastalıkların erken dönemde teşhis edilip ve diğer ağaçlara yayılmadan önce gerekli önlemlerin alınması oldukça önemlidir [2].

Elma meyvesindeki hastalıklar elma yaprakları ve meyvenin kendisi üzerinde belirti oluşturmaktadır. Hastalıklar meyvelerin kalitesi düşmektedir. Özellikle meyvelerdeki lekeli yüzeyler meyvenin pazar değerini

düşürmekte ve verim üzerinde düşüşe yol açmaktadır [3]. Elma üretim miktarını düşüren ana faktörler; hastalıklar, ekolojik faktörler, profesyonel ekipman kullanılmaması ve bilinçsiz yapılan tarım uygulamalarından kaynaklanmaktadır. Yüksek tüketime ve tıbbi faydalara sahip elma ağaçları, böcekler ve bakteri gibi mikroorganizmalar nedeniyle oluşan çeşitli hastalıklara eğilimlidir. Elma ağaçlarına zarar veren çeşitli hastalıklar vardır. Bu hastalıkların sık karşılaşılanlarından bazıları kara çürüklük, sedir elma pası ve elma kabuğu uyuz hastalıklarıdır [4]. Bu hastalıklar yapraklar üzerinden henüz meyveler zarar görmeden teşhis edilebilmektedir. Yapraklar üzerinden teşhis edilebilen bu tür hastalıkların erken fark edilmesiyle birlikte tedbirler alınıp muhtemel zararın önüne geçilebilir. Bu hastalıkların teşhisi için çiftçiler ve tarım uzmanları fiziksel ve görsel inceleme teknikleri kullanılmaktadır. Bu yöntemler için üretim olan bölgelerde uzman ihtiyacı doğmaktadır. Gelişen teknoloji ve yapay zeka uygulamaların yaygınlaşması ile bu alanda uzman ihtiyacını azaltarak elma ağaçlarındaki hastalıkların tespitinde çiftçilere yardımcı olabilmektedir [5,6].

Yapay zeka, alanındaki gelişmeler ile birlikte sağlık [7], robotik [8], eğitim [9], tarım [10] ve mantar tespiti [11] gibi birçok alanda kullanılmaya başlamıştır. Özellikle tarım alanında hastalık tespiti, ürün rekolte tahmini, ürün kalite sınıflaması gibi birçok alanda yapılan çalışmalar bulunmaktadır.

Kirola ve arkadaşları, bitki yaprağı hastalıklarının sınıflandırılması için hem makine öğrenimi hem de derin öğrenme yöntemlerini karşılaştırmıştır. Makine öğrenmesi yöntemlerinden Destek Vektör Makinesi (SVM), En Yakın Komşu (KNN), Rastgele Orman (RF), Lojistik Regresyon (LR), ve Derin Öğrenme(DL) kullanmışlardır ve en başarılı sonuç RF yöntemiyle 97,12'lik doğruluk oranı elde etmiştir. Derin öğrenme yöntemlerinden ise kullandıkları CNN modeli %98,43'lük doğruluk oranı elde etmiştir [12].

Salatalık yaprak hastalıklarını tespit etmek için yapılan, bir çalışmada AlexNet modeli uygulanmış ve %93,40 doğruluk oranına ulaşılmıştır. Çalışmada kullanılan veri setinde 14,208 adet görsel kullanılmıştır. Bu çalışma Juncheng Ma ve arkadaşları tarafından yapılmıştır [13].

AlexNet modelinin kullanıldığı bir başka çalışmada Chen ve arkadaşları domates yapraklarındaki hastalıkları tespiti yapmışlardır. Yapılan çalışmada %98,00 doğruluk oranı elde edilmiştir [14].

Sulistyowati ve arkadaşları elma ağacının yapraklarından bitki hastalıklarını tespit etmişlerdir. Yaptıkları çalışmada VGG16 ve önerdikleri SmoteVGG16 modellerini karşılaştırmışlardır. VGG16 ile %85,16'lık bir başarımler elde ederken SmoteVGG16 modeli ile %92,94'lük bir başarımler elde etmişlerdir [15].

F.O Babalola ve arkadaşları plant village veri setinde bulunan elma yapraklarındaki hastalıkları derin öğrenme yöntemleriyle tespiti için çalışma yapmışlardır. Veri setinde bulunan görselleri veri artırma teknikleriyle

çoğaltarak 12,264 veriye çıkartmışlardır. AlexNet ile yaptıkları sınıflandırma sonunda %99,56'lık bir başarımler elde etmişlerdir[16].

S. Baranwalve arkadaşları 2019 yılında alma elma yaprağı görüntülerin hastalık tespiti üzerine çalışmışlardır. Plant Village veri setini kullanmışlardır. Kullandıkları veri setinde sadece eğitim verileri üzerinde veri artırma tekniklerini uygulamışlardır. GoogleNet ile yaptıkları eğitim sonrasındaki testlerinde %98,54'lük bir başarımler elde etmişlerdir [17].

Bu çalışmada literatüre farklı transfer öğrenme yöntemleriyle elma hastalıklarının tespiti konusunda katkı sağlamak amacıyla elma ağacı yaprak görüntülerinden, elma ağaçlarında yaygın olarak karşılaşılan kara çürüklük, sedir elma pası ve elma kabuğu uyuz hastalıklarının teşhisi yapılmıştır. Gerçek bitki hastalıkları görüntülerinden oluşan PlantVillage veri seti kullanılmıştır. Transfer öğrenme tabanlı derin öğrenme modelleri olan Xception, InceptionV3 kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. Önerilen modellerde PlantVillage veri seti üzerinde; Xception modelinde %99,84, InceptionV3 modelinde %98,58 doğruluk oranı elde edilmiştir.

2. MATERYAL VE METOT

Bu çalışmada, elma yapraklarındaki hastalıkların transfer öğrenme yöntemleriyle tespit edilmesi amaçlanmıştır. Eğitim ve test işlemleri için PlantVillage veri seti kullanılmıştır. Veri seti üzerinde veri artırma teknikleri uygulanmıştır. Derin öğrenme yöntemlerinden Xception ve InceptionV3 transfer öğrenme yöntemleri kullanılmıştır. Uygulama Python diliyle yazılmış ve Google Colab üzerinde eğitim ve test işlemleri gerçekleştirilmiştir.


Bu bölümün devamında kullanılan veri setinden, elma yaprağı hastalıklarından, transfer öğrenme yöntemlerinden ve değerlendirme metriklerinden bahsedilmiştir.

2.1. PlantVillage Veri Seti

PlantVillage veri seti, bitki hastalıklarının teşhisi ve tarım teknolojileri için geliştirilmiş geniş kapsamlı bir veri setidir. PlantVillage, Kaggle platformu üzerinden herkese açık bir şekilde paylaşılmaktadır. Çalışma kapsamında Kaggle üzerinden indirilmiştir. PlantVillage 14 farklı bitki türüne ait 54.306 yaprak görüntüsünü içermektedir. Görüntüler, uzmanlar tarafından etiketlenmiş olup, toplamda 38 farklı hastalık sınıfını kapsamaktadır. Veri seti, hem laboratuvar ortamında çekilmiş kontrollü görüntüleri hem de doğal ortamlarda çekilmiş saha görüntülerini içermekte olup, makine öğrenmesi ve bilgisayarla görü teknolojilerinin tarım alanında uygulanmasında önemli bir kaynak sunmaktadır [18].

Bu çalışma kapsamında, PlantVillage veri setindeki yalnızca elma ağacının yaprak görüntüleri kullanılmıştır. Veri setinde, elma yapraklarına ait çeşitli hastalıkları ve

sağlıklı yaprakları içeren toplam 3.651 görüntü bulunmaktadır. Elma yaprakları için kara çürüklük, sedir elma pası ve elma kabuğu uyuz hastalıkları ve sağlıklı yaprakları temsil eden toplam dört sınıf bulunmaktadır. Veri seti içerisindeki sınıflara ait görsellerin dağılımı Şekil 1’de verilmiştir.



Şekil 1. PlantVillage veri seti sınıf dağılımı

Şekil 1’de görülen veri seti dağılımı dengeli bir veri seti olmadığını göstermektedir. Sağlıklı yapraklara ait 1645 görsel varken sedir elma pası hastalığına ait görsel sayısı 275’tir. Bu verilerin %80’i eğitim ve %20 test için kullanılmak üzere ayrılarak eğitim ve test işlemleri gerçekleştirilmiştir.

2.1.1. Sağlıklı Elma Yapağı

Sağlıklı yapraklar tamamen lekesiz ve yeşil olarak gözükmemektedir. Leke veya şekil bozuklukları elma yapağındaki hastalık olma ihtimalini arttırmaktadır. Kullanılan veri setinde toplam 1645 sağlıklı yaprak bulunmaktadır ve bu sayı veri setinin %45,06’ini oluşturmaktadır. Sağlıklı yapağına örnek görsel Şekil 2’de verilmiştir.



Şekil 2. Sağlıklı elma yapağı görseli

2.1.2. Elma kabuğu (Uyuz) hastalığı

Elma kabuğu (Uyuz) hastalığı, yapraklarda kahverengi lekeler bulunan bir hastalıktır. Uyuz, genellikle yapraklara ve meyvelere etki eden bir mantardan kaynaklanır. Kullanılan veri setinde elma kabuğu hastalığına sahip toplam 630 görsel bulunmaktadır ve bu

sayı veri setinin %17,26’sını oluşturmaktadır. Şekil 3’te elma kabuğu hastalığına ait veri setinden örnek bir görsel sunulmuştur.



Şekil 3. Elma kabuğu hastalığı olan yaprak görseli

2.1.3. Kara Çürüklük

Kara çürüklük hastalığı, mantarların neden olduğu bir hastalıktır. Yaprak yüzeylerinde bulunan mor lekeler; yaprak yaşlandıkça kenar boşluklarında kalır, merkezler kurur ve sarıdan kahverengiye döner. Kullanılan veri setinde toplam 621 kara çürüklük hastalığına sahip yaprak görseli bulunmaktadır ve bu sayı veri setinin %17,01’ini oluşturmaktadır. Şekil 4’te kara çürüklük hastalığına ait veri setinden örnek bir görsel sunulmuştur.



Şekil 4. Kara çürüklük hastalığı olan yaprak görseli

2.1.4. Sedir Elma Pası

Sedir elma pası hastalığının belirtileri yapraklarda sarımsı lekelerdir. Bitkilerde pas genellikle pas mantarı adı verilen benzersiz bir mantardan kaynaklanır. Kullanılan veri setinde toplam 275 sedir elma pası hastalığına sahip yaprak görseli bulunmaktadır ve bu sayı veri setinin %7,53’ini oluşturmaktadır. Şekil 5’te sedir elma pası hastalığına ait veri setinden örnek bir görsel sunulmuştur.



Şekil 5. Sedir elma pası hastalığı olan yaprak görseli

2.2. Veri Ön İşleme

Veri setlerinde görüntü sayısının az olduğu durumlarda veri artırma yöntemleri kullanılmaktadır [19]. Bu yöntemlerdeki mevcut görselleri döndürme, öteleme, kırma, soldurma, ölçeklendirme ve gürültü ekleme gibi işlemlere tabi tutarak elde edilen mevcut verilerden yeni sentetik veriler üretilmesini sağlamaktadır. Bu çalışmada veri artırma işlemleri Python'da bulunan ImageDataGenerator kütüphanesi ile gerçekleştirilmiştir. ImageDataGenerator Tablo 1'de verilen değerler ile çalıştırılmıştır.

Tablo 1. Veri artırma için kullanılan özellikler tablosu

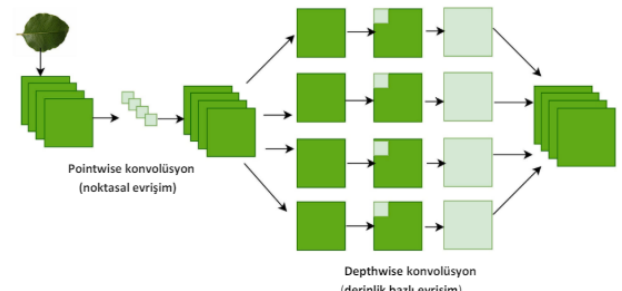
Özellik	Değer
Yeniden Öçeklendirme	1/255
Rastgele Döndürme	20
Rastgele Yatay Kaydırma	0,2
Rastgele Dikey Kaydırma	0,2
Rastgele Kesme	0,2
Yatay Döndürme	Evet
Doldurma	Nearest

2.3. Derin Öğrenme

Derin öğrenme, verileri sınıflamak için katmanından birden fazla işlem oluşan çok seviyeli bir makine öğrenmesi yöntemidir [20]. Derin öğrenme modelleri eğitimi yapılırken yeniden eğitim gerçekleştirilebilir veya daha önce eğitilen bir modelin farklı bir amaç için eğitildiği nokta başlangıç notası olarak verilip yeni görev için eğitilebilmektedir. Daha önce eğitilmiş bir modeli farklı görev için eğitme işlemine transfer öğrenme denilmektedir. Literatürde transfer öğrenme yöntemleri sıklıkla kullanılmaktadır [21]. Bu çalışmada transfer öğrenme yöntemlerinden Inception V3 ve Xception yöntemleri kullanılmıştır.

2.3.1. Xception

Xception transfer öğrenme modeli, klasik evrişim katmanlarının yerine derinlik-ayrık evrişimleri kullanarak çalışır. Her bir evrişim işlemi kanallara ayrılır ve her kanal ayrı ayrı işlenir. Ardından, bu kanallar birleştirilir. Bu yapı, modeli daha verimli hale getirir ve daha derin özellikleri öğrenmesine olanak tanır [22]. Xception modelinin bu çalışma yapısı Şekil 6'da sunulmuştur.




Şekil 6. Xception model yapısı

Xception modeli oluştururken girdi boyutları (224,224,3) olarak verilmiştir. Havuzlama katmanlarında avarage pooling yöntemi seçilmiştir. Tam bağlantı katmanının girişinde 256 nöron kullanılmış ve aktivasyon fonksiyonu Relu olarak belirlenmiştir. Çıkış katmanında ise hastalık sınıflarını temsil eden 4 nöron bulunmakta ve aktivasyon fonksiyonu olarak softmax belirlenmiştir. Aşırı uyumu önlemek için dropout katmanı eklenmiştir. Ayrıca oluşturulan modelde Adamax optimizasyon algoritması ve categorical_crossentropy kayıp fonksiyonu kullanılmıştır. Eğitimin epoch değeri 5 olarak belirlenmiştir. Çalışmada Xception modeli ile Inception V3 modeli kıyaslanacağı için veri seti karıştırılmadan eğitim başlatılmıştır.

2.3.2. InceptionV3

InceptionV3, görüntüleri sınıflandırmak için farklı boyutlardaki filtreleri paralel olarak uygulayan Inception modüllerini kullanır. Bu sayede, model hem daha derin hem de geniş olmaktadır. Bu nedenle görüntülerden daha karmaşık özellikler çıkarır ve sınıflandırma performansını artırmaktadır [23]. Inception V3 modelinin mimari yapısı Şekil 7'de sunulmuştur.



Şekil 7. InceptionV3 model yapısı [24]

Inception V3 için oluşturulan modelin parametreleri güvenilir bir karşılaştırma yapabilmek için Xception'da verilen parametreler ile aynı tutulmuştur. Benzer şekilde kullanılan katman özellikleri, epoch sayısı, kayıp fonksiyonu da Inception V3 modeli ile aynı olarak seçilmiştir.

2.4. Metrikler

Makine öğrenimi ve derin öğrenme modellerini değerlendirmek ve karşılaştırmak için kullanılan çeşitli metrikler bulunmaktadır. Bu metrikler, modelin ne kadar iyi performans gösterdiğini ölçmek ve diğer yapılan çalışmalarla kıyaslamak için kullanılır. Yaygın olarak kullanılan dört temel değerlendirme metriği doğruluk

(accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skor (F1 score) metrikleridir. Bu metriklerin haricinde modelin hangi sınıf bazlı performansını görselleştirmek için karmaşıklık matrisi kullanılmaktadır. Karmaşıklık Matrisi ve diğer metrikler hesaplanırken matrisi doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerleri ile hesaplama yapılır.

Doğru Pozitif (TP): Modelin, bir yaprakta gerçekten hastalık olduğunda ve model bunu doğru bir şekilde tespit ettiği duruma denir.

Doğru Negatif (TN): Modelin, bir yaprakta gerçekten hastalık olmadığına ve model bunu doğru bir şekilde tespit ettiği duruma denir.

Yanlış Pozitif (FP): Modelin, sağlıklı bir yaprağı hasta olarak etiketlediği duruma denir.

Yanlış Negatif (FN): Modelin, hasta bir yaprağı sağlıklı olarak etiketlediğine denir. Bu temel bileşenler kullanılarak çeşitli doğruluk, hassasiyet, duyarlılık, F1 Skor ve karmaşıklık matrisi hesaplanır [25].

Karmaşıklık matrisi, bir modelin performansının doğru bir şekilde değerlendirmek için kullanılan ve yapılan tahminlerin sınıf bazlı olarak tablo şeklinde sunulduğu bir gösterim biçimidir. Karmaşıklık matrisi ile hangi sınıfların tahmini için model zayıftır yada model hangi sınıf ile hangi sınıfı birbirine karıştırmış gibi çıkarımların yapılabilmesine olanak tanır. Karmaşıklık matrisinde de doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) temel bileşenleri kullanılır. Karmaşıklık matrisinin örnek bir gösterimi Şekil 8'de sunulmuştur [26].

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 8. Karmaşıklık matrisi örneği

Doğruluk, modelin genel performansını değerlendirir. Tüm doğru tahminlerin toplamının, toplam tahmin sayısına oranı olarak hesaplanır. Doğruluğun hesaplama formülü Eşitlik 1'de verilmiştir.

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

Hassasiyet, pozitif olarak tahmin edilen sonuçların ne kadarının gerçekten pozitif olduğunu gösterir. Yanlış pozitiflerin sayısının az olduğu durumlarda önemlidir. Hassasiyet hesaplama formülü Eşitlik 2'de verilmiştir.

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

Duyarlılık, gerçek pozitiflerin ne kadarının doğru bir şekilde tespit edildiğini gösterir. Yanlış negatiflerin

sayısının az olduğu durumlarda önemlidir. Duyarlılık hesaplama formülü Eşitlik 3'de verilmiştir.

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

F1-Skor, hassasiyet ve duyarlılığın harmonik ortalamasıdır. Hem yanlış pozitiflerin hem de yanlış negatifleri dengelemeye çalışır. Birbirinden bağımsız çalışmalarda modelleri kıyaslamak için uygun bir parametredir. F1-Skor hesaplama formülü Eşitlik 4'de verilmiştir.

$$F1\ Skor = 2 \times \frac{Hassasiyet \times Duyarlılık}{Hassasiyet + Duyarlılık} \quad (4)$$

Bir sonraki bölümde bu bölümde bahsedilen metrikler ile yapılan çalışma değerlendirilip sonuçları sunulmuştur.

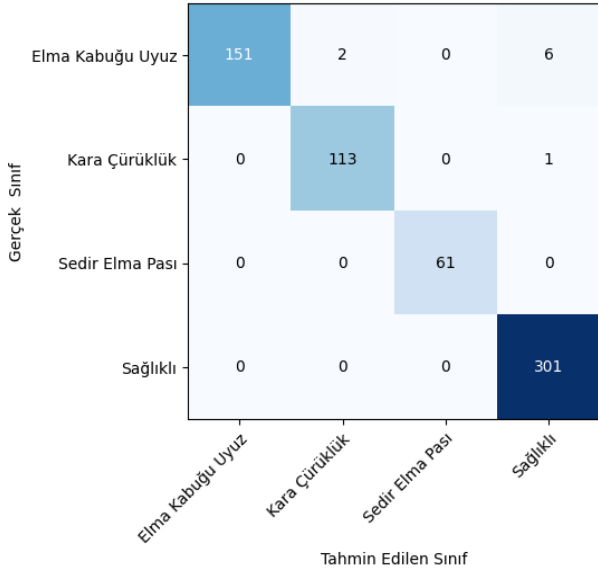
3. BULGULAR

Çalışmada elma ağacı hastalıklarını yaprak görselleri üzerinden teşhis etmek için yapay zeka eğitimi gerçekleştirilmiştir. Xception ve Inception V3 transfer öğrenme yöntemleri kullanılarak iki farklı eğitim yapılmıştır. Kullanılan yöntemler doğruluk, duyarlılık, hassasiyet, F1 skoru metrikleri karşılaştırma yapıp, karmaşıklık matrisi üzerinden incelemeler yapılmıştır.

Tablo 2. Model performans karşılaştırma tablosu

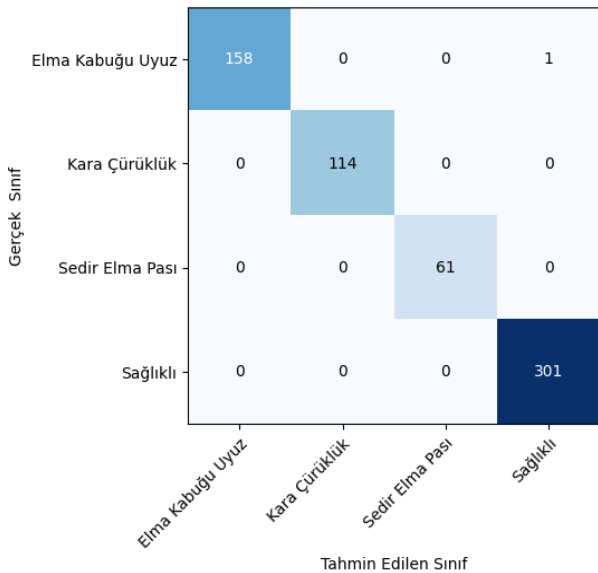
Model	Doğruluk	Duyarlılık	Hassasiyet	F1 Skoru
Xception	%99,84	%99,84	%99,92	%99,88
Inception V3	%99,58	%99,74	%99,00	%99,52

Tablo 2'de sunulan test sonuçlarına sonuçlar genel olarak birbirine %1'lik bir farktan daha yakın çıkmıştır. Xception %99,84'lük bir doğruluk elde ederken, InceptionV3 modeli %99,58'lük doğruluk elde etmiştir. F1 skor sonuçlarına bakıldığında %99,88 ile Xception modeli yüksek bir skor elde ederken, benzer şekilde Inception V3 modelinde %99,52'lik bir skor elde etmiştir. Genel bir değerlendirme yapıldığında aralarındaki fark az olsa da Xception modeli daha yüksek bir başarımla elde etmiştir.



Şekil 9. Inception V3 karmaşıklık matrisi

Inception V3 için oluşturulan karışıklık matrisi Şekil 9 'da görülmektedir. Karışıklık matrisine bakıldığında sağlıklı yaprakların ve sedir elma pası hastalığına sahip yaprakların tamamını doğru bildiği görülmektedir. Ancak model sağlıklı olmayan 7 yaprağa sağlıklı olarak tahmin yaparken Sedir elma pası olmayan hiçbir yaprak için sedir elma pası tahmini yapmamıştır. Elma Kabuğu Uyuz Hastalığı ise en başarısız olduğu sınıftır. Elma kabuğu hastalığı içeren görsellerin 8 tanesini bilememiştir. Bunların 2 tanesine kara çürüklük tahmininde bulunurken, 6 tanesine de sağlıklı olarak tahmin yapmıştır. Kara çürüklük hastalığı bulunan görsellerin sadece 1 tanesini doğru tahmin edemeyip sağlıklı yaprak olarak tahmin etmiştir.



Şekil 10. Xception karmaşıklık matrisi

Xception için oluşturulan karışıklık matrisi Şekil 10'da görülmektedir. Matris incelendiğinde Kara çürüklük, Sedir elma pası ve sağlıklı yaprakların tamamını doğru tahmin etmiştir. Sadece Elma Kabuğu (Uyuz) Hastalığına ait bir görseli sağlıklı olarak tahmin etmiştir. Modelin test kümesi için yaptığı tek yanlış bu örnek için olmuştur. Bu

sonuç oldukça yüksek bir başarımla olan %99,84'lük doğruluğu sağlamıştır.

4. TARTIŞMA VE SONUÇ

Bu çalışmada elma üretiminde verimliliği arttırmanın en önemli parçalarından biri olan bitki hastalıklarıyla mücadelede hastalık tespiti için yapay zeka modeli kullanılmıştır. Geliştirilen model ile hastalık teşhisi yapılırken gerek duyulan uzmana olan ihtiyacın en aza indirilmesi hedeflenmiştir.

Çalışmada transfer öğrenme yöntemlerinden Xception ve Inception V3 modelleri kullanılmıştır. Önceden eğitilmiş olan bu modeller PlantVillage veri setinde bulunan elma yaprakları için tekrar eğitilmişlerdir. PlantVillage veri setinde kara çürüklük, sedir elma pası, elma kabuğu uyuz hastalığı olmak üzere üç farklı hastalık ve sağlıklı yaprakların bulunduğu görseller üzerinde çalışılmıştır. Veri setindeki bu görsellerin arttırılması için veri ön işleme yöntemleri kullanılmıştır.

Yapılan yapay zeka eğitimi sonucunda Xception transfer öğrenme yöntemi %99,84'lik bir başarımla elde ederken Inception V3 modeli %99,58'lik bir başarımla elde etmiştir. Kullanılan iki yöntemde sonuçları birbirine oldukça yakındır. Yapılan test sonuçlarında Inception V3 9 yaprağı hatalı tahmin ederken Xception sadece 1 yaprak görselini hatalı tahmin etmiştir.

Kullanılan yöntemler oldukça başarılı sonuçlar elde etse de elma ağacında bulunan diğer hastalıklar için veri seti genişletilmelidir. Bitkilerde birbirinden farklı birçok hastalık bulunduğundan günlük hayattaki üreticinin hastalık teşhisi için uzman ihtiyacını en aza indirebilmektedir.

Gelecekteki çalışmalarda elma ağacının bilinen tüm yaprak hastalıklarını kapsayacak şekilde veri seti genişletilerek bir model eğitimi gerçekleştirilebilir. Ayrıca model bir uygulama ile desteklenerek teşhis edilen hastalık için çözüm önerisi sunması üreticinin hastalıkla olan mücadelesini kolaylaştırabilir.

Etik Hususlar

Finansman

Yazarlar, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almamıştır.

Çıkar çatışması

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

KAYNAKÇA

- [1] Hollomon, D.W., Brent, K.J., 2009. Combating plant diseases—the Darwin connection. *Pest Manag Sci*, 65, 1156–1163.
- [2] Topçu, C., Güneş, P., 2024. Bitki Hastalıklarını Tespitte Derin Öğrenme: ResNet Modelinin

- Etkinliği. *Journal of Anadolu Bil Vocational School of Higher Education*, 19, 31–65.
- [3] Yiğit, A., Turan, K., Erkiş, L., 1991. Studies on Fruit Scars of Citrus in Eastern Mediterranean Region of Türkiye. *Bitki Koruma Bülteni*, 31.
- [4] Aksoy, B., Diyar HALİS, H., Khaled Musleh SALMAN, O., Uygulamalı Bilimler Üniversitesi, I., et al., 2020. Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2, 194–210.
- [5] Singh, T., Kumar, K., Bedi, S.S., 2021. A Review on Artificial Intelligence Techniques for Disease Recognition in Plants. *IOP Conf Ser Mater Sci Eng*, 1022, 012032.
- [6] Singh, V., Sharma, N., Singh, S., 2020. A review of imaging techniques for plant disease detection. *Artificial Intelligence in Agriculture*, 4, 229–242.
- [7] Ahuja, A.S., 2019. The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ*. <https://doi.org/10.7717/peerj.7702>
- [8] Talaş, U., Yüzgeç, U., Çubukçu, B., 2021. Object Recognizing Robot Application with Deep Learning. *European Journal of Science and Technology*, 127–133.
- [9] Arslan, K., Üyesi, Ö., Eylül Üniversitesi, D., 2020. Eğitimde Yapay Zeka ve Uygulamaları Artificial Intelligence and Applications in Education. *Derleme Makale Western Anatolia Journal of Educational Sciences*, 11, 71–80.
- [10] Ozdemir, D., Kunduraci, M.S., 2022. Comparison of deep learning techniques for classification of the insects in order level with mobile software application. *IEEE Access*, 10, 35675–35684.
- [11] Akın, M., Dağdelen, A., Eğinme, R.N., Özdemir, D., 2023. Doğada Yetişen Mantar Türlerinin Derin Öğrenme ile Tespiti. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 4, 29–36.
- [12] Kirola, M., Joshi, K., Chaudhary, S., Singh, N., et al., 2022. Plants Diseases Prediction Framework: A Image-Based System Using Deep Learning. *Proceedings - 2022 IEEE World Conference on Applied Intelligence and Computing, AIC* 307–313.
- [13] Ma, J., Du, K., Zheng, F., Zhang, L., et al., 2018. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network. *Comput Electron Agric*, 154, 18–24.
- [14] Chen, H.C., Widodo, A.M., Wisnujati, A., Rahaman, M., et al., 2022. AlexNet Convolutional Neural Network for Disease Detection and Classification of Tomato Leaf. *Electronic*, Vol. 11, Page 951, 11, 951.
- [15] Sulistyowati, T., PURWANTO, P., Alzami, F., Pramunendar, R.A., 2023. VGG16 Deep Learning Architecture Using Imbalance Data Methods For The Detection Of Apple Leaf Diseases. *Moneter: Jurnal Keuangan dan Perbankan*, 11, 41–53.
- [16] Babalola, F.O., Kpai, N.I., Toygar, Ö., 2023. Deep Learning Based Classification of Apple Leaf Diseases Using AlexNet. *Computer Science*, 67–74.
- [17] Baranwal, S., Khandelwal, S., Arora, A., 2019. Proceedings of international conference on sustainable computing in science, technology and management (SUSCOM), Amity University Rajasthan, Jaipur-India.
- [18] Mohanty, S.P., Hughes, D.P., Salathé, M., 2016. Using deep learning for image-based plant disease detection. *Front Plant Sci*, 7, 215232.
- [19] Ergün, E., Kılıç, K., 2021. Derin Öğrenme ile Artırılmış Görüntü Seti üzerinden Cilt Kanseri Tespiti. *Black Sea Journal of Engineering and Science*, 4, 192–200.
- [20] Lecun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *Nature* 521:7553, 521, 436–444.
- [21] Weiss, K., Khoshgoftaar, T.M., Wang Background, D., 2016. A survey of transfer learning. <https://doi.org/10.1186/s40537-016-0043-6>
- [22] Lo, W.W., Yang, X., Wang, Y., 2019. An xception convolutional neural network for malware classification with transfer learning. *2019 10th IFIP International Conference on New Technologies, Mobility and Security, NTMS 2019 - Proceedings and Workshop*.
- [23] Xia, X., Xu, C., Nan, B., 2017. Inception-v3 for flower classification. *2nd International Conference on Image, Vision and Computing, ICIVC*, 783–787.
- [24] Stefenon, S.F., Yow, K.-C., Nied, A., Meyer, L.H., 2022. Classification of distribution power grid structures using inception v3 deep neural network. *Electrical Engineering*, 104, 4557–4569.
- [25] Blagec, K., Dorffner, G., Moradi, M., Samwald, M., n.d. A critical analysis of metrics used for measuring progress in artificial intelligence. <https://doi.org/10.48550/arXiv.2008.02577>
- [26] Erickson, B.J., Kitamura, F., 2021. Magician’s corner: 9. performance metrics for machine learning models. *Radiol Artif Intell*, 3. <https://doi.org/10.1148/ryai.2021200126>