

Derin Öğrenme Modelleri ve Veri Ön İşleme Yöntemleri ile Çeltik Yaprak Hastalıklarının Erken Teşhisi

Cüneyt ÖZDEMİR*¹ ORCID 0000-0002-9252-5888

¹Siirt Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Siirt

Geliş tarihi: 18.07.2023

Kabul tarihi: 29.09.2023

Atıf şekli/ How to cite: ÖZDEMİR, C., (2023). Derin Öğrenme Modelleri ve Veri Ön İşleme Yöntemleri ile Çeltik Yaprak Hastalıklarının Erken Teşhisi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 38(3), 807-817.

Öz

Son yıllarda tarım sektöründe, derin öğrenme temelli bilgisayar destekli sistemler büyük bir önem kazanmış ve farklı uygulama alanlarında etkili bir rol oynamıştır. Bu sistemler sadece hastalıkların erken teşhisine katkı sağlamakla kalmamış, aynı zamanda tarım profesyonellerine önemli bir destek sunmuştur. Bu bağlamda, bu çalışma çeltik yapraklarında mevcut hastalıkların erken teşhisinde derin öğrenme yöntemlerinin etkinliğini araştırmayı amaçlamaktadır. Bu araştırma için, 13 farklı çeltik hastalığına ait toplam 4160 görüntü içeren Paddy Doctor veri kümesi kullanılmıştır. Veri kümesi üzerinde beş farklı transfer öğrenme modeli titizlikle değerlendirilmiştir. Elde edilen sonuçlar, Xception modelinin %93,37'lik doğruluk oranı ile en üstün performansı gösterdiğini açıkça ortaya koymaktadır. Ayrıca, bu çalışma veri ön işleme ve veri artırma tekniklerini optimize etme konusuna da değinerek veri kümesini zenginleştirmeyi ve teşhis doğruluğunu artırmayı amaçlamıştır. Başarılı bulunan modelin çeltik yaprak hastalıklarını teşhis etmedeki performansı ayrıntılı bir şekilde değerlendirilmiştir. Bu değerlendirme sonucunda, modelin en başarılı olduğu hastalık sınıfları belirlenmiş ve aynı şekilde modelin en zorlandığı veya en düşük doğruluk oranına sahip hastalık sınıfları da tespit edilmiştir. Bu bulgular, çeltik hastalıklarının erken teşhisinde transfer öğrenme modellerinin potansiyelini vurgulayarak tarım sektöründe etkili otomatik teşhis sistemlerinin geliştirilmesine olanak tanımaktadır. Bu yaklaşım, tarım sektöründe mahsul verimini artırma ve pestisit kullanımını azaltma yolunda umut vadetmektedir. Ayrıca, daha sağlıklı ve sürdürülebilir tarım uygulamalarını teşvik etme odaklı bu araştırma, gelecekteki stratejilere de katkı sağlayabilir.

Anahtar Kelimeler: Paddy doctor, Xception, derin transfer öğrenme, Çeltik hastalıkları

Early Diagnosis of Paddy Leaf Diseases using Deep Learning Models and Data Preprocessing Techniques

Abstract

In recent years, deep learning-based computer-aided systems have gained significant importance in the agriculture sector and have played an effective role in various application areas. These systems have not only contributed to the early diagnosis of diseases but have also provided crucial support to agricultural professionals. In this context, this study aims to investigate the effectiveness of deep learning methods in the early diagnosis of rice leaf diseases. For this research, the Paddy Doctor dataset, comprising a total of 4160 images from 13 different rice diseases, was utilized. Five different transfer learning models were meticulously evaluated on the dataset. The results clearly indicate that the Xception model achieved the

*Sorumlu yazar (Corresponding Author): Cüneyt ÖZDEMİR, cuneytozdemir33@gmail.com

highest performance with an accuracy rate of 93.37%. Additionally, this study aimed to enrich the dataset and improve diagnostic accuracy by optimizing data preprocessing and augmentation techniques. The performance of the successful model in diagnosing rice leaf diseases was thoroughly assessed. Through this evaluation, disease categories in which the model excelled and those in which it struggled or had the lowest accuracy rates were identified. These findings underscore the potential of transfer learning models in the early diagnosis of rice diseases, facilitating the development of effective automated diagnostic systems in the agriculture sector. Furthermore, this research, with a focus on promoting healthier and sustainable agricultural practices, may contribute to future strategies.

Keywords: Paddy doctor, Xception, deep transfer learning, Paddy diseases

1. GİRİŞ

Çeltik, dünya nüfusunun çoğunluğu tarafından besin kaynağı olarak kullanılan önemli bir üründür. Eğer dünya genelindeki nüfus artış hızı mevcut oranda devam ederse, 2030 yılında çeltik talebini karşılamak için üretimin %50 artırılması gerekmektedir. Çeltik üretiminde dünya genelinde önde gelen ülkeler arasında Çin, Hindistan, Endonezya, Bangladeş ve Vietnam bulunmaktadır. Dünya çeltik verimi 410 kg/da (dekara) olup, Türkiye'nin ortalama dekara çeltik verimi ise 780 kg'dır. Türkiye'de çeltik tarımı 31 ilde gerçekleştirilmekte olup, en çok Edirne, Balıkesir, Çorum, Samsun, Sinop ve Kastamonu illerinde ekilmektedir. Çeltik, beslenme açısından gerekli amino asitler açısından zengin bir içeriğe sahip olan bir üründür ve bu nedenle buğdaydan sonra tercih edilen ürünler arasında yer alır. Çeltik tarımı için toprak seçimi konusunda belirli bir kriter olmasa da, çeltik yetiştiriciliği için en uygun koşulları sağlayan topraklar, az su geçirgenliği, derinlik, tınlı yapısı ve besin maddeleri açısından zengin olmasıdır. Kumlu topraklar, su kaybına ve besin maddeleri eksikliğine neden olabileceği için çeltik yetiştiriciliği için uygun değildir [1].

Çeltik, yurtiçi ve yurtdışı pazarlarda tercih edilen temel bir tarım ürünü olarak tanınan yüksek verimli bir tahıl ürünüdür. Yüksek getiri sağlaması nedeniyle çeltik, üreticiler için önemli bir seçenektir. Dünya nüfusunun artması, refah seviyesinin yükselmesi ve alışkanlıkların değişmesiyle birlikte, Türkiye ve diğer birçok ülkede çeltik tüketiminde artış eğilimi gözlenmektedir [2].

Tarımın ve gıda üretiminin sürdürülebilirliği, çeltik üretiminin verimliliği ile yakından ilişkilidir. Ne yazık ki, çeltik üretimi, çeşitli hastalıkların neden olduğu risklerle karşı karşıyadır. Bu hastalıkların tarımsal üretkenliği olumsuz etkilediği ve ekonomik kayıplara yol açtığı yaygın bir gerçektir. Çeltik yetiştiriciliği, birçok hastalık ve zararlıdan etkilenen karmaşık bir süreçtir. Bu hastalıkların erken teşhisi, tarımcılar ve tarım uzmanları için kritik bir görevdir. Geçmişte çiftçiler, hastalıkları tespit etmek için büyük ölçüde kendi bilgilerine ve çeltik mahsullerini görsel olarak incelemeye güveniyorlardı. Ne yazık ki bu yöntemlerin verimsiz, zaman alıcı ve hataya açık olduğu kanıtlanmıştır. Deneyimli çiftçiler ve tarım uzmanları bile benzer belirtiler gösteren farklı hastalıkları doğru bir şekilde teşhis etmekte zorluklarla karşılaşmaktadır [3-5].

Çeltik hastalıklarının otomatik tespiti, bu zorlukları aşmak için daha etkili, doğru ve ekonomik bir yöntem sunarak hastalıkları tanımlama ve yönetme sürecini iyileştirebilir. Telefon kameraları, standart kameralar, spektrometreler ve termal sensörler dahil olmak üzere çeşitli sensörler, çeltik bitkileri hakkında veri toplamak için otomatik algılama sistemleri tarafından kullanılabilir. Söz edilen sensörler aracılığıyla elde edilen veriler, makine öğrenimi algoritmalarıyla analiz edilerek hastalıkların erken aşamada tespit edilmesi sağlanabilir. Çeltik hastalıklarının otomatik olarak tespit edilmesi, mahsul verimini artırmak, pestisit kullanımını azaltmak ve çevreyi korumak gibi büyük potansiyellere sahiptir. Farklı hastalıkların tanımlanması için makine öğrenimi modellerinin kullanımı son zamanlarda kayda değer bir artış

göstermiştir. Bu modeller, kesin sonuçlar sağlamadaki dikkate değer doğruluklarıyla tanınmıştır.

Ramesh ve Vydeki [6], Çeltik bitkisinin hastalıklarının (Kahverengi leke, Bakteriyel yanıklık, Yaprak yanığı ve Yaprak kımı çürüklüğü) tespiti için optimize edilmiş derin sinir ağları ve Jaya algoritmasını kullanmışlardır. Bu çalışmada, görüntülerdeki arka planın çıkarılması ve hastalıklı ile sağlıklı bitki görüntülerinin ayrıştırılması için RGB renk uzayı, HSV (Ton, Doyma, Değer) renk uzayına dönüştürülmüştür. Toplamda 650 çeltik bitkisinin yaprak görüntüsü kullanılarak elde edilen sonuçlar, %94.25 doğruluk oranı sağlamıştır.

Bhagawati ve arkadaşları [7], çeltik yanıklığı hastalığını öngörmek amacıyla, sıcaklık, bağıl nem, yağış ve rüzgâr hızı gibi hava parametreleri ile bir sinir ağı eğitmişlerdir.

Lu ve arkadaşları [8], 10 farklı çeltik bitkisi hastalığı üzerinde araştırma yapmışlardır. Çeltik yanıklığı, yalancı leke, kahverengi leke, çeltik bakanae, yaprak yanıklığı, yaprak çürümesi, bakteriyel yaprak yanıklığı, bakteriyel yaprak çürümesi, tohum yanıklığı ve bakteriyel solgunluk hastalıklarını sınıflandırmak amacıyla 500 çeltik bitkisi görüntüsü kullanmışlardır. Elde ettikleri sonuçlar, geleneksel yöntemlere göre daha iyi olduğu ancak CNN tabanlı modellerin eğitimi için yeterli veri setine sahip olmadıklarını belirtmişlerdir.

Prajapati ve arkadaşları [9], çeltik bitkisinin üç farklı hastalığını tespit etmek amacıyla görüntü işleme yöntemi ve Destek Vektör Makinesi (SVM) kullanmışlardır. Bu çalışmada elde edilen doğruluk oranı %73,33 olarak saptanmıştır.

Rahman ve arkadaşları [10], çeltik bitkisinin hastalığını tespit etmek için CNN kullanmış ve %93,3 doğruluk oranı elde etmiştir.

Lu ve arkadaşları [11] tarafından yapılan çalışmada, çeltik bitkisine ait on farklı hastalığı sınıflandırmak

amacıyla 500 çeltik bitkisi görüntüsü kullanılarak basit bir evrişimli sinir ağı (CNN) modeli geliştirilmiştir. Elde edilen sonuçlara göre, bu çalışma kapsamında elde edilen doğruluk oranı %95,48 olarak tespit edilmiştir.

Ökten ve arkadaşları [12], 5000 adet çeltik bitkisi yaprağında hastalığı %91,54 oranında tespit etmiştir. Daha sonra 5000 görüntü veri artırma yöntemi ile 8000 görüntüye çıkarılmış ve CNN mimarisinin hiper-parametrelerini değiştirerek %97,57'lik bir başarı oranı elde edildiği belirtilmiştir.

Bu tarz hastalıklarla etkili bir mücadele yöntemi olarak, güncel teknolojiler arasında makine öğrenmesi öne çıkmaktadır. Makine öğrenmesi, büyük veri setlerini analiz etme yeteneği sayesinde hastalıkların erken teşhisinde ve sınıflandırılmasında önemli bir rol oynamaktadır. Özellikle makine öğrenmesinin alt dalı olan derin transfer öğrenme modelleri, bu tür karmaşık ve geniş veri setlerinde yüksek başarı elde etme potansiyeline sahiptir. Derin öğrenme sağlık, gıda, spam filtreleme gibi birçok sektörde geniş bir uygulama potansiyeline sahip olan önemli bir teknoloji olarak öne çıkmaktadır [13-17]. Bu çalışmada da makine öğrenimi teknolojilerinden derin transfer öğrenme modellerinin kullanılmasıyla, 13 farklı çeltik hastalığının yüksek doğrulukla tespit edilmesi başarılmıştır. Bu sonuçlar, çeltik tarımındaki hastalık teşhisinin iyileştirilmesi ve tarım verimliliğinin artırılmasına yönelik umut verici bir perspektif sunmaktadır.

2. MATERYAL VE METOT

2.1. Materyal

Bu çalışma için paddy doctor [18] veri kümesi kullanılmıştır. Bu veri kümesinde 13 farklı çeltik hastalığına ait veri bulunmaktadır. Her gruptan 320 görüntü olmak üzere toplamda 4160 görüntü kullanılmıştır. Veri setine ait sınıflar ve bunlara ait sayılar Çizelge 1'de gösterilmiştir.


Çizelge 1. Bitki hastalıkları veri seti

Hastalık	Eğitim Sayısı	Test Sayısı
Tungro	320	80
Sarı kök kurdu (Yellow stem borer)	320	80
Hispa	320	80
Tüylü küf (Downy mildew)	320	80
Siyah gövde kurdu (Black stem borer)	320	80
Bakteriyel yaprak çizgisi (Bacterial leaf streak)	320	80
Bakteriyel yaprak yanıklığı (Bacterial leaf blight)	320	80
Kahverengi leke (Brown spot)	320	80
Yanıklık (Blast)	320	80
Yaprak silindiri (Leaf roller)	320	80
Normal	320	80
Bakteriyel salkım yanıklığı (Bacterial panicle blight)	320	80
Beyaz gövde kurdu (White stem borer)	320	80
Toplam	4160	1040

Veri toplama işlemi Şubat ayından Nisan 2021'e kadar, paddy bitkisinin yaşı 40 ila 80 gün arasında olduğu dönemde gerçekleştirilmiştir. Her görüntü, bir tarım görevlisiyle işbirliği yapılarak hastalık belirtilerinin varlığına dayanarak el ile etiketlenmiş ve bir hastalık sınıfı etiketi atanmıştır. Paddy bitki hastalıkları etiketleri şunlardır [18]:

- Bakteriyel Yaprak Solgunluğu (BLB)
- Bakteriyel Yaprak Çizgilenmesi (BLS)
- Bakteriyel Başak Solgunluğu (BPB)
- Kara Gövde Kurdu (BSB)
- Yanıklık
- Kahverengi leke
- Paslanma
- Hispa
- Yaprak Sürücüsü
- Tungro
- Beyaz Gövde Kurdu
- Sarı Gövde Kurdu
- Normal yaprak.

Şekil 1'de veri setinde yer alan farklı sınıflara ait birer örnek içeren görüntüler verilmiştir.



Şekil 1. Her sınıfa ait bir görüntü

Literatür taraması yapıldığında, çeltik hastalıklarının farklı türleriyle ilgili birçok çalışma ve bu hastalıklara ait çeşitli toplanmış veri setleri bulunmaktadır. Bu çalışmada özellikle sürekli olarak güncellenen Paddy Doctor veri seti kullanılmıştır. Bu veri seti, literatürde çok fazla çalışmada kullanılmıştır. Bu çalışmalarda, model performansını artırmak için genellikle veri setindeki sınıf sayısı azaltılmıştır. Ayrıca, sınıflar arasındaki görüntü sayılarının dengesizliğini gidermek ve model performansını iyileştirmek için aynı sayıda görüntü kullanılmıştır. Paddy Doctor veri setinin bu dinamik yapısı, farklı araştırma projelerinde benzersiz bir değer ve uyum sağlayıcı bir özellik olarak öne çıkmaktadır.

Bu veri seti sürekli olarak güncellenmekte olup, bu çalışma kapsamında 4160 görüntü içeren veri seti kullanılmıştır.

2.2. Metot

Transfer öğrenimi, makine öğreniminde yaygın olarak kullanılan bir teknik olup, veriden özellik çıkarma konusunda hali hazırda yetkin olan önceden eğitilmiş bir modelin, farklı bir görevi hedefleyen yeni bir model için temel olarak kullanıldığı bir yöntemdir. Bu yaklaşım, bir modeli sıfırdan eğitime ihtiyacını ortadan kaldırarak zamandan ve kaynaklardan tasarruf etme avantajı sunar. Popüler transfer öğrenme modelleri arasında Xception, ResNet, MobileNet, DenseNet ve Inception yer almaktadır.

InceptionV3: InceptionV3, derin öğrenme alanında yaygın olarak kullanılan bir evrişimli sinir ağı (CNN) modelidir. Girdi veriyi çoklu paralel yollarla işleyen ve daha sonra bu parçaları birleştiren "incelemeli" mimariye dayanır. Bu yapı, daha iyi öznetelik çıkarma yeteneği sağlayarak nesne tanıma ve sınıflandırma görevlerinde etkili sonuçlar elde etmeyi amaçlar [19].

ResNet101V2: ResNet101V2, "Derin İlişkili Ağlar" (Residual Networks) olarak da bilinen ResNet ailesinin bir üyesidir. ResNet mimarisi, ağı derinleştikçe performansın düşmesini engellemeyi amaçlar. Residual blokları adı verilen özgün yapılar, girdi ve çıkış arasındaki farkları öğrenerek ağı daha kolay öğrenmesini sağlar [20].

Xception: Xception, temelde InceptionV3'ün geliştirilmiş bir versiyonu olarak kabul edilir. "Derin İlişkili Ağlar" (Residual Networks) olarak da bilinen ResNet ailesinin bir üyesidir. Ancak Xception, girdi verinin özneteliklerini daha detaylı analiz etmek için derinlemesine ayrılmış paralel katmanlar kullanır [21].


MobileNetV2: MobileNetV2, hafif ve hızlı derin öğrenme modeli olarak tasarlanmıştır. Mobil cihazlar gibi kaynak sınırlı ortamlarda kullanılmak üzere optimize edilmiştir. Yüksek performansı düşük hesaplama maliyetiyle birleştiren bir yapı sunar [22].

DenseNet121: DenseNet, ağ katmanları arasında yoğun bağlantıların kurulduğu bir CNN mimarisidir. Geleneksel CNN'lere kıyasla daha etkili bilgi akışını sağlar. "Yoğun bloklar" olarak adlandırılan yapılarıyla bilgi paylaşımını artırarak daha iyi öznetelik çıkarma yeteneği sunar [23].

Transfer öğrenme modellerinin kullanımı çeşitli avantajlar sunar. İlk olarak, doğruluğu artırırken eğitim süresini önemli ölçüde azaltır. Ayrıca, sınırlı miktarda veriyle bile yüksek doğruluk elde edilmesini sağlayabilir. Bununla birlikte, bu yaklaşımda dikkatli model seçimi gerekliliği, model performansını optimize etmek için ince ayar gerekliliği ve önceden eğitilmiş modeli eldeki veri kümesinin belirli özelliklerine uyarlama ihtiyacı gibi bazı dezavantajları vardır.

Bu çalışmada, transfer öğrenme modellerini Paddy Doctor veri setinin benzersiz özelliklerine uyarlandı. Daha sonra bu uyarlanmış modellerin performansı veri kümesi üzerinde titizlikle incelendi ve analiz edildi.

Bu çalışma için model mimarisi Şekil 2'de gösterilmiştir. Veri kümesi öncelikle ön işleme tabi tutulmuştur. Ardından, transfer öğrenme modelleri kullanılarak görüntülere ait özellikler çıkarılmıştır. Son olarak, özellikler 128, 64 ve 32 nöronlu 3 katmanlı bir yapay sinir ağına beslenmiştir. Aşağıda, Şekil 2'de gösterilen adımlar adım adım açıklanmıştır.



Şekil 2. Model Mimarisi

Veri ön işleme: Başlangıçta, veriler dikkatli bir ön işleme sürecinden geçirilmiştir. Veri setindeki görüntüler, ilk olarak 256x256 boyutuna yeniden boyutlandırılmıştır. Bu işlem sonrasında, veri

setinin çeşitliliğini artırmak amacıyla çeşitli veri artırma teknikleri özenle uygulanmıştır. Bu teknikler arasında dönüş aralığı (rotation_range) 10 derece, kayma aralığı (shear_range) 0.2 ve

yakınlaştırma aralığı (zoom_range) 0.2 gibi parametreler optimize edilmiştir. Ayrıca, genişlik kayması aralığı (width_shift_range) 0.05, yükseklik kayması aralığı (height_shift_range) 0.05 ve kanal kayması aralığı (channel_shift_range) 0 olarak ayarlanmıştır. Veri artırma işlemleri sırasında, görüntülerin işlenmesini kolaylaştırmak ve normalize etmek amacıyla 1/255 ölçeklendirme (rescale) işlemi uygulanmıştır. Bu parametre değerleri, bir dizi deneysel çalışmanın sonucunda titizlikle belirlenmiş ve en iyi sonuçların elde edildiği değerlerdir. Ayrıca, batch boyutu 128 olarak belirlenmiştir ki bu, deneylerin hızlı ve etkili bir şekilde gerçekleştirilmesine olanak sağlamıştır.

Özellik çıkarma: Verilerden özelliklerin çıkarılması aşaması, bu noktada evrimsel sinir ağları (CNN) gibi transfer öğrenme modellerinin yardımıyla yapılmıştır. Bu adımın temel amacı, görsel verilerde bulunan karmaşıklığı ve önemi anlamak için verilerden anlamlı özelliklerin çıkarılmasıdır. Özellikle, çeltik yapraklarının hastalıklarını tespit etmek için kritik olan özellikleri belirlemek bu aşamanın odak noktasıdır. CNN modelleri, verilerin içerdiği bilgileri hiyerarşik olarak analiz eder ve bu sayede görüntülerdeki desenleri ve özellikleri tanımlamada son derece etkilidirler. Özellik çıkarmanın bu aşaması, daha sonra modelin eğitiminde kullanılacak olan temel veri temsillerini oluşturur. Bu sayede, farklı çeltik hastalıklarını ayırt etmek için gerekli olan bilgi elde edilmiş olur.

Model eğitimi: Özellikler, başarılı bir hastalık teşhis modeli oluşturmak için model eğitimi aşamasında kullanılırlar. Bu aşama, özelliklerin önceki işlemlerle işlenmesinden sonra elde edilen veri temsillerini modelin anlayabileceği bir formata dönüştürmeyi içerir. Model eğitimi, bu veri temsillerini kullanarak bir yapay sinir ağı oluşturmayı içerir. Bu çalışmada, modelin mimarisi 128, 64 ve 32 nöronlu üç katmandan oluşan bir yapay sinir ağı olarak belirlenmiştir. Bu katmanlar, özelliklerin daha yüksek düzeyde temsil edilmesini sağlar. Model, veriler arasındaki karmaşıklıkları ve ilişkileri öğrenerek, çeltik yaprak hastalıklarını doğru bir şekilde sınıflandırma yeteneğine sahip olur. Model eğitimi aşaması, verilerin üzerindeki desenleri tanımayı öğrenerek, sonunda güvenilir ve

doğru teşhisler yapabilen bir yapay zeka modelinin oluşturulmasını sağlar. Özellikler çıkarıldıktan sonra, bir modeli eğitmek için kullanılırlar. Model eğitimi 128, 64 ve 32 nöronlu 3 katmandan oluşan yapay sinir ağları ile gerçekleştirilmiştir.

Bu çalışmada, çeltik yaprak hastalıklarının erken teşhisinde derin öğrenme tabanlı transfer öğrenme modellerinin etkinliğini ve bu modellerin performansını değerlendirmek için çeşitli metrikler kullanılmıştır.

2.3. Performans Metrikleri

Accuracy (Doğruluk): Doğru tahmin edilen örneklerin toplam örnek sayısına oranını ifade eder. Bu metrik, genel sınıflandırma başarısını yüzde cinsinden gösterir.

F1 Score: F1 skoru, hassasiyet (precision) ve duyarlılık (recall) metriklerinin harmonik ortalamasını ifade eder. Bu metrik, dengeli sonuçları değerlendirmek için kullanılır.

Recall (Duyarlılık): Duyarlılık, gerçek pozitif sayısının, gerçek pozitif sayısı ve yanlış negatif sayısı toplamına bölünmesi ile hesaplanır. Duyarlılık, yanlış negatiflerin kaçırılma oranını ifade eder.

Precision (Hassasiyet): Hassasiyet, gerçek pozitif sayısının, gerçek pozitif sayısı ve yanlış pozitif sayısı toplamına bölünmesi ile hesaplanır. Hassasiyet, yanlış pozitiflerin oranını ifade eder.

Bu metrikler, çeltik yaprak hastalıklarının tespiti için kullanılan transfer öğrenme modellerinin performansını objektif bir şekilde değerlendirmek ve sonuçları daha iyi anlamak amacıyla kullanılmıştır.

Çizelge 2. Performans metriklerinin matematiksel formülleri

Metrik	Formül
Accuracy	$(TP+TN)/(TP+TN+FP+FN)*100$
Recall	$TP/(TP+FN)$
Precision	$TP/(TP+FP)$
F-Measure	$\{2 \times (\text{Recall} \times \text{Precision})\} / (\text{Recall} + \text{Precision})$

Bu denklemlerde T, F, P ve N sırasıyla Doğru, Yanlış, Pozitif ve Negatif anlamına gelmektedir. Örneğin, TP doğru sınıflandırılmış pozitif örneklerin sayısını; FN ise yanlış sınıflandırılmış negatif örneklerin sayısını göstermektedir.

3. DENEYSEL SONUÇLAR

Ön işlemden sonra veri kümesi eğitim, doğrulama ve test kümelerine ayrılmıştır. Eğitim veri kümesi görüntülerin %75'ini içerirken, görüntülerin kalan %25'i test veri kümesini oluşturmak için kullanılmıştır.

Eğitim veri kümesi, toplamda 4160 görüntüden oluşmaktadır. Bu görüntüler 13 farklı sınıfa ayrılmıştır ve her sınıfta 320 görüntü bulunmaktadır. Doğrulama veri kümesi içinse eğitim veri setinin %15'i ayrılmıştır, toplam 624 görüntüden oluşmaktadır.

Geriye kalan 3536 görüntü ise eğitim sürecinde kullanılmak üzere ayrılmıştır. Test veri kümesi ise 13 farklı sınıfa ait toplam 1040 görüntüden oluşmaktadır. Her sınıfta 80 görüntü bulunmaktadır. Bu şekilde, veri kümesinin farklı bölümleri arasında benzerlik oluşmasını engellemek ve daha akıcı bir ayrıma ulaşmak

amaçlanmıştır. Çeltik hastalıklarını sınıflandırmak amacıyla, Xception, ResNet101V2, MobileNetV2, DenseNet121 ve InceptionV3 gibi yaygın olarak kullanılan transfer öğrenme modelleri kullanılmıştır. Bu çalışmada, transfer öğrenme modelleri öznitelik çıkarmak amacıyla kullanılmıştır. Bu modeller, en iyi öznitelikleri çıkararak önerilen modelin en yüksek başarı skorlarını elde etmeye odaklanmıştır. Transfer öğrenme modellerine herhangi bir fine tuning işlemi yapılmamıştır. Tüm modeller için Adam optimizasyon algoritması kullanılarak optimizasyon gerçekleştirilmiştir. Eğitim sürecinde, öğrenme oranı 0.001 olarak ayarlanmış ve her model 100 epok boyunca çalıştırılmıştır. Optimum performansı sağlamak için ModelCheckpoint ve EarlyStopping yöntemleri, modelin en yüksek performansı sergilediği noktada eğitimi durdurmak için uygulanmıştır. Batch boyutu 128 olarak belirlenmiştir.

Deneyler veri seti üzerinde gerçekleştirilmiş ve transfer öğrenme modellerinin çeltik hastalıklarını sınıflandırmadaki performansları incelenmiştir. Elde edilen sonuçlar, farklı transfer öğrenme modellerinin doğruluk, hassasiyet, özgünlük ve F1 skoru gibi ölçütler üzerinden analiz edilerek Çizelge 3'te sunulmuştur.

Çizelge 3. Transfer öğrenme modelleri performans sonuçları

	Accuracy	F1 score	Recall	Precision
InceptionV3	%89,62	%89,67	%89,62	%89,98
ResNet101V2	% 71,35	%71,46	%71,35	%73,99
Xception	%93,37	%93,42	%93,37	%93,65
MobileNetV2	%87,60	%87,63	%87,60	%88,54
DenseNet121	%92,31	%92,27	%92,31	%92,34

Çizelge 3'e göre, Xception modeli %93,37'lik bir doğruluk oranıyla en iyi sonuçları elde etti. InceptionV3 modeli %89,62, ResNet101V2 modeli %71,35, MobileNetV2 modeli %87,60 ve DenseNet121 modeli ise %92,31 doğruluk elde etti.

Şekil 3, Xception modelinin kayıp ve doğruluk performansının bir grafiğini göstermektedir. Model, eğitim ilerledikçe kayıplarını azaltmış ve doğruluğunu artırmıştır.


Doğruluk, modelin test veri setindeki görüntüleri ne sıklıkla doğru sınıflandırdığının bir ölçüsüdür. Xception modelinin doğruluğu %93,37'dir, yani görüntülerin %93,37'sini doğru bir şekilde sınıflandırmıştır.

Hassasiyet, modelin pozitif olduğunu tahmin ettiği görüntüleri ne sıklıkla doğru sınıflandırdığının bir ölçüsüdür. Xception modelinin hassasiyeti %93,65'tir; bu da modelin pozitif olduğunu tahmin

ettiği görüntülerin %93,65'inin gerçekten pozitif olduğu anlamına gelir.

Kesinlik, modelin test veri kümesindeki tüm pozitif görüntüleri ne sıklıkla doğru sınıflandırdığının bir

ölçüsüdür. Xception modelinin kesinlik oranı %93,37'dir; bu da modelin test veri kümesindeki tüm pozitif görüntülerin %93,37'sini doğru sınıflandırdığı anlamına gelmektedir.



Şekil 3. Xception modeline ait kayıp ve doğruluk grafiği

Şekil 4, Xception modelinin test veri kümesi üzerindeki sınıflandırma performansını gösteren bir karmaşıklık matrisini göstermektedir. Bu matris, her bir sınıfa göre kategorize edilen model

tarafından doğru ve yanlış sınıflandırılan görüntülerin sayısına ilişkin kapsamlı bir genel bakış sağlar.

Karmaşıklık Matrisi

Gerçek Etiket	Bacterial Leaf Blight -	73	0	0	0	2	2	1	2	0	0	0	0	0
	Bacterial Leaf Streak -	0	79	0	0	1	0	0	0	0	0	0	0	0
	Bacterial Panicle Blight -	0	0	80	0	0	0	0	0	0	0	0	0	0
	Black Stem Borer -	0	0	0	77	0	0	0	0	0	0	0	2	1
	Blast -	0	0	0	0	71	1	5	2	1	0	0	0	0
	Brown spot -	0	0	0	0	1	72	2	0	0	3	0	0	0
	Downy Mildew -	0	0	0	0	4	0	75	1	0	0	0	0	0
	Hispa -	0	1	0	0	0	0	3	70	1	4	0	1	0
	Leaf Roller -	0	0	0	0	1	0	0	2	77	0	0	0	0
	Normal -	0	0	0	0	0	0	0	6	0	74	0	0	0
	Tungro -	0	0	0	0	3	0	1	3	0	3	70	0	0
	White Stem Borer -	0	0	1	1	0	0	0	0	0	0	0	78	0
	Yellow Stem Borer -	1	0	0	0	0	0	0	0	0	0	0	1	75
			Bacterial Leaf Blight -	Bacterial Leaf Streak -	Bacterial Panicle Blight -	Black Stem Borer -	Blast -	Brown spot -	Downy Mildew -	Hispa -	Leaf Roller -	Normal -	Tungro -	White Stem Borer -

Tahmin edilen Etiket

Şekil 4. Xception modeline ait karmaşıklık matrisi

Şekil 4'deki karmaşıklık matrisi, test veri kümesinde Xception modeli tarafından doğru ve yanlış sınıflandırılan görüntülerin sayısını

göstermektedir. Matris, Xception modelinin 971 görüntüyü doğru sınıflandırdığını ve 69 görüntüyü yanlış sınıflandırdığını göstermektedir.

Çizelge 4, 13 farklı sınıfa ayrılmış görüntülerdeki çeltik hastalıklarını kategorize etmek için Xception modelinin uygulanmasıyla elde edilen sınıflandırma sonuçlarını göstermektedir. Bu tablo, her bir sınıftaki görüntülerin başarı oranını yüzde

olarak belirtmek için çeşitli metrikler kullanılmaktadır. Bu metrikler arasında doğruluk, hassasiyet, özgünlük ve F1 skoru gibi ölçütler bulunmaktadır. Ayrıca, her sınıfa ait test görüntü sayıları da belirtilmektedir.

Çizelge 4. Xception sınıflandırma raporu

	Precision	Recall	F1-Score	Support
bacterial_leaf_blight	%96,1	%91,3	%93,6	80
bacterial_leaf_streak	%98,8	%98,8	%98,8	80
bacterial_panicle_blight	%98,8	%100	%99,4	80
black_stem_borer	%98,7	%96,3	%97,5	80
blast	%85,5	%88,8	%87,1	80
brown_spot	%96,0	%90,0	%92,9	80
downy_mildew	%86,2	%93,8	%89,8	80
hispa	%81,4	%87,5	%84,3	80
leaf_roller	%97,5	%96,3	%96,9	80
normal	%88,1	%92,5	%90,2	80
tungro	%100	%87,5	%93,3	80
white_stem_borer	%91,8	%97,5	%94,5	80
yellow_stem_borer	%98,7	%93,8	%96,2	80
accuracy			%93,4	1040
macro_avg	%93,6	%93,4	%93,4	1040
weighted_avg	%93,6	%93,4	%93,4	1040

Çizelge 4, Xception modelinin bakteriyel salkım yanıklığı (bacterial_panicle_blight) sınıfı için %99,4 F1-skoru ile tüm sınıflar için en yüksek F1-skorunu elde ettiğini göstermektedir. Sınıflandırma raporu, modelin bakteriyel yaprak yanıklığı (bacterial leaf blight), bakteriyel yaprak çizgisi (bacterial leaf streak) ve bakteriyel salkım yanıklığı(bacterial panicle blight) sınıfları için en yüksek hassasiyete ve kesinliğe sahip olduğunu göstermektedir. Model, hispa sınıfı için en düşük hassasiyet ve kesinliğe sahip iken, tungro sınıfı için en düşük kesinliğe sahiptir.

4. SONUÇLAR

Bu çalışma, çeltik hastalıklarının sınıflandırılmasında transfer öğrenme modellerinin kullanımının yanı sıra yapılan veri ön işleme adımlarının ve yapay sinir ağı nöron seçiminin sonuçlara olan etkisini incelemeyi amaçlamıştır. Xception modeli, test veri kümesinde %93,37'lik bir doğruluk elde ederek en yüksek performansı

sergileyerek dikkat çekmektedir. Ancak, bu başarıya ulaşmadan önce veri ön işleme süreçleri ile çeşitli yapay sinir ağı nöron seçenekleri üzerinde titiz bir çalışma yürütülmüştür. Bu sonuçlar, çeltik hastalıklarının sınıflandırılmasında kullanılan yöntemlerin seçimi ve veri işleme adımlarının sonuçlar üzerindeki etkisinin önemini vurgulamaktadır.

Bu çalışmanın sonuçları, çeltik hastalıklarını etkili bir şekilde sınıflandırmak için transfer öğrenme modellerinin kullanılabilirliğini göstermektedir. Xception modeli en etkili model olarak bulunmuştur, ancak diğer modeller de yüksek doğruluk elde etmiştir. Transfer öğrenme modellerinin kullanımı, bir modeli sıfırdan eğitmek gerekmediği için zaman ve kaynak tasarrufu sağlayabilir. Bu da transfer öğrenme modellerini çeltik hastalıklarının tespitine yönelik otomatik sistemlerin geliştirilmesi için umut verici bir yaklaşım haline getirmektedir.

Bu çalışmanın sonuçları, çeltik hastalıklarının daha etkili ve doğru bir şekilde tespit edilmesi amacıyla kullanılabilir. Bu sistem, çiftçiler tarafından hastalıkları erken aşamada tespit etmek ve yönetmek için kullanılabilir ve bu da ürün kayıplarını azaltmaya yardımcı olabilir. Sistem ayrıca araştırmacılar tarafından çeltik hastalıklarının gelişimini incelemek için de kullanılabilir.

Bu çalışmanın sonuçları, sınırlı bir veri kümesi kullanıldığında elde edilen sonuçlar üzerine odaklanmıştır. Daha büyük bir veri kümesinin kullanılması, transfer öğrenme modellerinin performansını daha kapsamlı bir şekilde değerlendirilmesine olanak tanıyacaktır. Bu nedenle, gelecekte yapılacak çalışmaların, çeltik hastalıklarının sınıflandırılmasında transfer öğrenme modellerinin daha yüksek bir veri kümesi üzerindeki performansını daha ayrıntılı bir şekilde incelenmesi gerekmektedir. Elde edilen sonuçlar, daha büyük veri setleri kullanmanın bu tür otomatik teşhis sistemlerinin başarısını daha da artırabileceği bir potansiyeli işaret etmektedir.

5. KAYNAKLAR

1. T.C. Tarım ve Orman Bakanlığı Yayınları, 2007. Çeltik Hastalık ve Zararlıları ile Mücadele, https://www.tarimorman.gov.tr/GKGM/Belgeler/Uretici_Bilgi_Kosesi/Dokumanlar/celtik.pdf Erişim Tarihi: 16.05.2023, Ankara.
2. Taşlıgil, N., Şahin, G., 2011. Türkiye’de Çeltik (*Oryza Sativa* L.) Yetiştiriciliği ve Coğrafi Dağılımı. Adıyaman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 4(6), 182-204.
3. Amritha, H., Jeena, T., Ebin D.R., 2023. Deep Learning System for Paddy Plant Disease Detection and Classification. Environmental Monitoring and Assessment, 195, 1(2023),1–28.
4. Leelavathy, B., Rao Kovvur, R.M., 2020. Prediction of Biotic Stress in Paddy Crop Using Deep Convolutional Neural Networks. In Proceedings of International Conference on Computational Intelligence and Data Engineering. Springer Singapore, 337-346.
5. Shrivastava, V.K., Pradhan, M.K., Minz, S., Thakur, M.P., 2019. Rice Plant Disease Classification Using Transfer Learning of Deep Convolution Neural Network. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences XLII-3/W6 (July 2019), 631-635.
6. Ramesh, S., Vydeki, D., 2020. Recognition and Classification of Paddy Leaf Diseases Using Optimized Deep Neural Network with Jaya Algorithm. Information Processing in Agriculture, 7(2), 249-260.
7. Bhagawati, R., Bhagawati, K., Singh, A.K.K., Nongthombam, R., Sarmah, R., Bhagawati, G., 2015. Artificial Neural Network Assisted Weather Based Plant Disease Forecasting System. International Journal on Recent and Innovation Trends in Computing and Communication, 3(6), 4168-4173.
8. Lu, R., 2004. Multispectral Imaging for Predicting Firmness and Soluble Solids Content of Apple Fruit. Postharvest Biology and Technology, 31(2), 147-157.
9. Prajapati, H.B., Shah, J.P., Dabhi, V.K., 2017. Detection and Classification of Rice Plant Diseases. Intelligent Decision Technologies, 11(3), 357-373.
10. Rahman, C.R., Arko, P.S., Ali, M.E., Iqbal Khan, M.A., Apon, S.H., Nowrin, F., Wasif, A., 2020. Identification and Recognition of Rice Diseases and Pests using Convolutional Neural Networks. Biosystems Engineering, 194, 112-120.
11. Lu, Y., Yi, S., Zeng, N., Liu, Y., Zhang, Y., 2017. Identification of Rice Diseases using Deep Convolutional Neural Networks. Neurocomputing, 267, 378-384.
12. Ökten, İ., Yüzgeç, U., 2022. Evrişimli Sinir Ağı ile Çeltik Bitkisi Hastalığının Tespiti. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 11(1), 203-217.
13. Kılıç, Ş., Doğan, Y. 2023. Deep Learning Based Gender Identification using Ear Images. Traitement du Signal, 40(4).
14. Dogan, Y., 2023. A New Global Pooling Method for Deep Neural Networks: Global Average of Top-K Max-Pooling. Traitement du Signal, 40(2).

15. Dogan, Y., Atas, M., Özdemir, C., 2014. A New Approach for Plotting Raster Based Image Files. In 2014 22nd Signal Processing and Communications Applications Conference (SIU), 1027-1030. IEEE.
16. Özdemir, C., Atas, M., Özer, A.B., 2013. Classification of Turkish Spam E-Mails with Artificial Immune System. In 2013 21st Signal Processing and Communications Applications Conference (SIU), 1-4. IEEE.
17. Kılıç, Ş., Kaya, Y., Askerbeyli, İ., 2021. A New Approach for Human Recognition Through Wearable Sensor Signals. *Arabian Journal for Science and Engineering*, 46, 4175-4189.
18. Petchiammal, A., Briskline Kiruba, S., Murugan, D., Pandarasamy, Arjunan., 2022. Paddy Doctor: A Visual Image Dataset for Automated Paddy Disease Classification and Benchmarking. *IEEE Dataport*.
19. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z., 2016. Rethinking the Inception Architecture for Computer Vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2818-2826.
20. He, K., Zhang, X., Ren, S., Sun, J., 2016. Identity Mappings in Deep Residual Networks. In *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part IV 14*, 630-645. Springer International Publishing.
21. Chollet, F., 2017. Xception: Deep Learning with Depthwise Separable Convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251-1258.
22. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.C., 2018. Mobilenetv2: Inverted Residuals and Linear Bottlenecks. In *Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition*, 4510-4520.
23. Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q., 2017. Densely Connected Convolutional Networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700-4708).

