

Derin öğrenme ağları kullanılarak mısır yapraklarında hastalık tespiti Disease detection in maize leaves using deep learning networks

Mustafa GÖKSU^{1*}, Kubilay Muhammed SÜNNETÇİ^{1,2}, Ahmet ALKAN¹

¹Department of Electrical and Electronics Engineering, Kahramanmaraş Sütçü Imam University, Kahramanmaraş, Turkey

²Department of Elect.and Electronics Engineering, Osmaniye Korkut Ata Univ., Osmaniye, Turkey
(mustafagoksu02@gmail.com, kubilaysunnetci@osmaniye.edu.tr, aalkan@ksu.edu.tr)

Received: Aug.31,2021

Accepted: Sep.26,2021

Published: Oct.20, 2021

Özetçe— Günümüzde insanların sağlıklı yaşayabilmeleri için temel besinlere kolayca erişebilmeleri gerekmektedir. Temel besinlerden olan mısırdaki insanoğlunun fizyolojik ihtiyaçlarını karşılayabilecek kaloringin sağlanması yanında mısırdaki yer alan B6 vitamini, sodyum, magnezyum, çinko, potasyum, kalsiyum, A vitamini gibi değerli mineraller ve vitaminler bulunmaktadır. Dünya’da ve ülkemizde dünya nüfusunun artmasıyla, mısırdaki ihtiyaç gün geçtikçe artmaktadır. Bu noktada, mısır üretiminin verimliliğini düşüren mısır yapraklarında görülen hastalıkların tespiti önemlidir. Gelişen teknolojiler sayesinde mısır yetiştiriciliğinde teknolojik imkânlar kullanılarak üreticilerin teşvik edilmesi gerekmektedir. Bu çalışma sayesinde, mısır yapraklarında görülen mısır pası, gri yaprak lekesi ve yaprak yanığı tespitinin gerçekleştirilmesi amaçlanmıştır. Ayrıca, derin öğrenme yöntemleri kullanılarak mısır yapraklarında görülen hastalıkların tespit edilebilmesi için EfficientNetB5 ağı ve evrimsel sinir ağları tabanlı iki adet model geliştirilmiştir. Oluşturulan modellerin performans metriklerini arttırabilmek için, görüntülerin sayısı veri çoğaltma teknikleri kullanılarak (aynalama, döndürme, büyütme) arttırılmıştır. Sonuçlardan, EfficientNetB5 transfer öğrenmesi modeli ve geliştirilen derin öğrenme modelinde elde edilen tahmin başarı oranlarının sırasıyla %92.12 ve %89.88’e eşit olduğu görülmektedir.

Anahtar Kelimeler: Derin öğrenme, görüntü işleme, evrimsel sinir ağları (ESA), mısır yaprağı hastalıkları, EfficientNetB5

Abstract— Nowadays, people need easy access to basic nutrients to live a healthy life. In addition to providing calories that can meet the physiological needs of human beings, maize, which is one of the basic foods, contains valuable minerals and vitamins such as vitamin B6, sodium, magnesium, zinc, potassium, calcium, vitamin A. As a result of the increase in the world population in the world and our country, the need for maize is increasing day by day. Herein, it is important to detect the diseases seen in maize leaves that reduce the efficiency of maize production. Thanks to the developing technologies, producers should be encouraged by using technological opportunities in maize cultivation. In the study, it is aimed to detect maize rust, gray leaf spot, and leaf blight on maize leaves. In addition, two models based on the EfficientNetB5 network and convolutional neural network have been developed to detect diseases found in maize leaves using deep learning methods. To increase the performance metrics of created models, the number of images has been increased by using data augmentation techniques (mirror, rotation, scale). From the results, it is seen that the prediction success rates obtained in the EfficientNetB5 transfer learning model and the developed deep learning model are equal to 92.12% and 89.88%, respectively.

Keywords: Deep learning, image processing, convolutional neural network (CNN), maize leaf diseases, EfficientNetB

1. Giriş

Gelişen teknolojiye paralel olarak karmaşık problemlerin çözülmesi için günümüzde birçok alanda makine öğrenmesi yöntemlerine başvurulmaktadır. Özellikle veri madenciliğinde yaşanan gelişmeler, verilerin kolay elde edilmesi ve işlenmesinden kaynaklanmaktadır. Özellikle internet yoluyla verilere hızlı, kolay ve ücretsiz erişim nedeniyle birçok yapay zekâ uygulaması geliştirilebilmektedir. Ayrıca, bilgisayarlı görü alanında son yıllarda yapılan çalışmalarda da görüldüğü gibi derin öğrenme ve makine öğrenmesi yöntemleri ile elde edilen yapay zekâ modelleri başarılı bir şekilde oluşturulabilmektedir. Bu uygulamalara örnek olarak; insanlığın yaşamını sürdürebilmesi ve sağlıklı beslenebilmesi için gerekli olan tarım ürünlerinin yetiştirilmesinde kullanılması önem arz etmektedir. Bu noktada, mısır üretiminde verimliliği düşüren ve mısır yapraklarında görülen hastalıkların tespiti bu yöntemler kullanılarak başarılı bir şekilde yapılmaktadır. Bu konuda, literatürde yapılmış birçok çalışma bulunmaktadır.


Yapılan çalışmalardan birisinde, mısır hastalık tespiti için farklı görüntü işleme tekniklerinden faydalanılarak bir sistem geliştirilmesi amaçlanmıştır. RGB (Red Green Blue) gibi renklerin algılanabilmesi açısından çeşitli özellik çıkartma yöntemleri kullanılmıştır. Bu çalışmada destek vektör makineleri, karar ağaçları, rastgele orman ve naive bayes sınıflandırıcıları kullanılmış ve çoğu sınıflandırıcı için RGB'nin algılanabilmesinde başarılı sonuçlar elde edilmiştir (Kusumo vd., 2018). Bir başka çalışmada, mısır hastalıklarının sınıflandırılmasında kullanılan destek vektör makinaları yerine genetik algoritmaları kullanan destek vektör makinaları ile daha başarılı sonuçların elde edilebileceği görülmüştür (Zhang vd., 2015). Mısır hastalıkları sınıflandırması yapılan başka bir çalışmada naive bayes, rastgele orman, destek karar vektörleri ve K-en yakın komşu teknikleri ile geliştirilen sınıflandırıcılardan en yüksek başarı oranı %79.23 olarak rastgele orman sınıflandırıcısından elde edilmiştir (Panigrahi vd., 2020). Mısır hastalıklarına ait 5 çeşit kategorinin sınıflandırılması için geliştirilen bilgisayarlı görü ile %80'den daha yüksek oranda başarı elde edilmiştir (Zhao vd., 2009). Mısır ve patates hastalıklarının sınıflandığı bir başka ise kullanılan sınıflandırıcıların başarı oranlarının %92.8 ile %97.89 arasında değiştiği görülmüştür (Akmal vd., 2020). Bir diğer taraftan mısır hastalıklarının sınıflandırılmasında konvolüsyonel sinir ağları kullanılarak bir akıllı telefon kamerası yardımıyla oluşturulan veri seti ile yapılan bu çalışmada sınıflandırma başarısının %92.85'e eşit olduğu görülmüştür (Sibiya ve Sumbwanyambe, 2019). Mısır hastalıklarının sınıflandırılması için CNN tabanlı LeNet kullanılarak geliştirilen sınıflandırıcının başarı oranının %97.89'a eşit olduğu görülmüştür (Priyadarshini vd., 2019). AlexNet kullanılarak yapılan çalışmada, geliştirilen sınıflandırıcının başarı oranının %98.62'ye eşit olduğu görülmüştür (Lv vd., 2020). Bitki yaprak hastalıkları tarımsal üretimlerde %42 oranında kayba neden olmaktadır. Bu nedenle, görüntüler üzerinden K-en yakın komşu sınıflandırıcısı kullanılarak %98.56 oranında başarı elde edilmiştir (Tulshan ve Raul, 2019). Mısır kuraklığını tanımak ve sınıflandırmak amacıyla yapılan bir çalışmada derin konvolüsyonel sinir ağının kullanıldığı görülmektedir. Sonuçlara göre, önerilen bu sistemin tanımlama ve sınıflama doğruluğunun sırasıyla %98.14 ve %95.95'e eşit olduğu görülmüştür (An vd., 2019). Mısır hastalıklarına ait 8 çeşit kategorinin sınıflandırılması işlemi GoogleLeNet mimarisi ile %98.9 oranında bir başarı elde edilmiştir. cifar veri seti ile geliştirilen sınıflandırıcı da ise %98.8'e eşit bir başarı elde edilmiştir (Zhang vd., 2018).

Bu çalışmada, toplam 4188 mısır yaprağı görüntüsünü 4 farklı kategori için sınıflandırılmıştır. Çalışmada kullandığımız veri setinde, mısır pası, gri yaprak lekesi, yaprak yanığı ve normal olmak üzere 4 farklı sınıf bulunmaktadır. Burada, verilen sınıflarda bulunan görüntülerin sayısı sırasıyla 1306, 574, 1146 ve 1162'ye eşittir. Çalışmada kullanılan tüm veri seti, sırasıyla %70 ve %30 oranında eğitim seti ve doğrulama seti olarak ayrılmıştır. Ayrıca, çalışmada kullanılan modellerde, aşırı öğrenme probleminin oluşmaması açısından eğitim aşamasında kullanılacak olan veriler çoğaltma teknikleri kullanılarak çoğaltılmıştır. Bu çalışmada, veri seti için EfficientNetB5 transfer öğrenmesi ve eğitim süresi ve dosya boyutu açısından avantaj sağlayan bir model kullanılarak görüntüler sınıflandırılmıştır. Bu noktada, her iki model de bazı değerlendirme metrikleri ve eğitim parametreleri açısından karşılaştırılmıştır.

2. Materyal

Bu bölümde, çalışmada kullanılan veri seti açıklanmaktadır. Veri seti Kaggle platformu üzerinden alınmıştır ("corn-or-maize-leaf-disease-dataset www.kaggle.com"). Burada, çalışma da kullanılan veri

seti JPG görüntülerinden oluşmaktadır. Çalışmada kullanılan bu görüntüler 4 farklı sınıfta incelenmektedir. Bu noktada, Şekil 1’de her sınıftan birer örnek gösterilmektedir.



Şekil 1. Veri setinde bulunan sınıflar için örnek görüntüler

Şekil 1.a-d’de çalışmada kullanılan veri setindeki sınıflara ait görüntüler bulunmaktadır. Burada, mısır yapraklarında görülen üç farklı hastalık çeşidi ve normal yaprak (sağlıklı yaprak) görüntüleri bulunmaktadır. Şekil 1.a-d’de sırasıyla mısır pası, gri yaprak lekesi, yaprak yanığı ve normal görüntüler gösterilmektedir. Ayrıca, çalışmada kullanılan veri seti toplamda 4188 adet görüntüden oluşmaktadır. Çalışmada kullanılan her sınıf için görüntü, eğitim ve doğrulama seti sayıları Tablo 1’de verilmiştir.

Tablo 1. Veri setinde bulunan görüntüler için görüntü sayısı istatistikleri


Görüntü sayısı	Mısır Pası	Gri Yaprak Lekesi	Yaprak Yanığı	Normal	Toplam
Eğitim seti %70	962	191	953	827	2933
Doğrulama seti %30	344	383	193	335	1255
Veri seti	1306	574	1146	1162	4188

Tablo 1 çalışmada kullanılan veri seti, eğitim seti ve doğrulama setlerinin boyutlarını göstermektedir. Ayrıca, eğitimde kullanılan görüntüler çoğaltma teknikleri ve keras kütüphanesinin görüntü verisi üretici (ImageDataGenerator) fonksiyonuyla artırılmıştır. Böylece eğitim başarısının artırılması ve aşırı öğrenmenin engellenmesi hedeflenmektedir. Ancak, bu çoğaltma işlemi doğrulama seti için kullanılmamaktadır. Buradaki toplam 4188 görüntünün 1306 tanesi mısır pası, 574 tanesi gri yaprak lekesi, 1146 tanesi yaprak yanığı ve 1162 tanesi normal olmak üzere veri setinde bulunmaktadır. Ayrıca, bu görüntülerin %70’i eğitim setinde ve %30’u da doğrulama setinde kullanılmıştır. Eğitim seti olarak belirlenen görüntüleri çoğaltmadan önce; mısır pası, gri yaprak lekesi, yaprak yanığı ve normal görüntülerinin sayısı sırasıyla 962, 191, 953 ve 827’ye eşittir. Bu noktada, doğrulama seti için bu görüntülerin sayısı sırasıyla 344, 383, 193 ve 335’tir.

3. Metotlar

Bu bölümde çalışmada kullanılan modeller açıklanmaktadır. Materyal kısmında kullanılan veri seti üzerinde iki farklı derin öğrenme modeli Kaggle platformu üzerinde çalıştırılmaktadır. Mısır yapraklarında hastalık sınıflandırmasını gerçekleştirecek derin öğrenme modellerinin eğitilmesi için iki model önerilmiştir. Model-1 olarak isimlendirilen model EfficientNetB5 ağı kullanılarak oluşturulmuştur. EfficientNetB5 ağı performans, verimlilik ve tahmin başarı oranının yüksek olması nedeniyle seçilmiştir (Tan ve Le, 2019). Model-2 olarak isimlendirilen modeli oluşturmak için evrişimli sinir ağı katmanları kullanılmıştır. Bu çalışmaya özgü 16 katman içeren bir ağ oluşturulmuştur. Bu ağda verilerden öz niteliklerin çıkarıldığı konvolüsyonel katmanlarında 4x4’lük filtreler ve aktivasyon

fonksiyonu olarak ReLu kullanılmıştır. Bu katmanlardan sonra 2x2'lik havuzlama katmanı ve %20 oranında katman azaltma işlemleri uygulanmıştır. Model-2'yi oluşturacak ağın giriş katmanı 50x50 piksellik görüntüler için tanımlanmıştır. Sınıflandırmanın yapıldığı en son katmanda softmax aktivasyon fonksiyonu kullanılmıştır. Model-1'de EfficientNetB5 ağı kullanılarak transfer öğrenmesi gerçekleştirilmiştir. Belirlenen veri seti üzerinde evrimsel sinir ağları kullanılarak bir model geliştirilmiştir. Çalışmada Model-1 olarak isimlendirilen modelin oluşturulması için EfficientNetB5 kütüphaneleri yüklenmiş ve Kaggle üzerinde sağlanan grafik işlemcileri ve işlemci kapasiteleri yüksek olan bilgisayarlar üzerinde model eğitimleri gerçekleştirilmiştir. Transfer öğrenmenin gerçekleştirileceği EfficientNetB5 ağına giriş çözünürlük değeri olan 400x400 piksele uygun olması için veri setinin tamamı OpenCv kütüphanesinin yeniden boyutlandırma fonksiyonu kullanılarak değiştirilmiştir. Yeniden boyutlandırılan bu veriler transfer öğrenmesi yönteminde kullanılmak üzere %70'i eğitim ve %30'u doğrulama seti olarak ayrılmıştır. Eğitimde kullanılacak verilerin daha iyi sonuç verebilmesi ve modelin aşırı öğrenme problemi oluşturmaması için keras kütüphanesinin görüntü verisi üretici fonksiyonu ile veriler üzerinde aynalama, döndürme, büyültme vb. işlemleri gerçekleştirilmiştir.



Şekil 2. Model-2'nin derin öğrenme blok diyagramı

Şekil 2'de, Model-2'nin ağ yapısını gösteren blok diyagramı verilmektedir. Bu yöntemi uygulamak için veri setinde yer alan JPG uzantılı dosyalar 50x50 piksele dönüştürülmüştür. Model-2 olarak geliştirilen derin öğrenme ağına, aşırı öğrenme probleminin önlenmesi için keras kütüphanesinden görüntü verisi üretici fonksiyonu kullanılmıştır. Giriş katmanından alınan verilerin öz niteliklerin çıkarılması için evrimsel konvülsiyonel ağ katmanlarında ReLU aktivasyon fonksiyonları kullanılmıştır (Alkan vd. 2021). Sonrasında bir önceki katmandan elde edilen veriler evrimsel konvülsiyonel ağa uygulanmadan önce, burada havuzlama ve katman azaltma işlemleri uygulanmıştır. Bu işlem birbirini izleyen 3 aşamada gerçekleştirildikten sonra tam bağlı katmana iletilmekte ve bu katmandan sonra sınıflandırma katmanında softmax fonksiyonu ile Şekil 1.a-d' de belirtilen 4 farklı sınıfa ait çıkışlar elde edilmektedir. Model-1 ve Model-2'nin karşılaştırılabilmesi için, eğitimde kullanılan iterasyon sayısı ve eğitimin gerçekleştirildiği ortamlar aynı olarak belirlenmiştir.

Tablo 2. Çalışmada kullanılan modeller için eğitim parametreleri ve bazı değerlendirme metrikleri

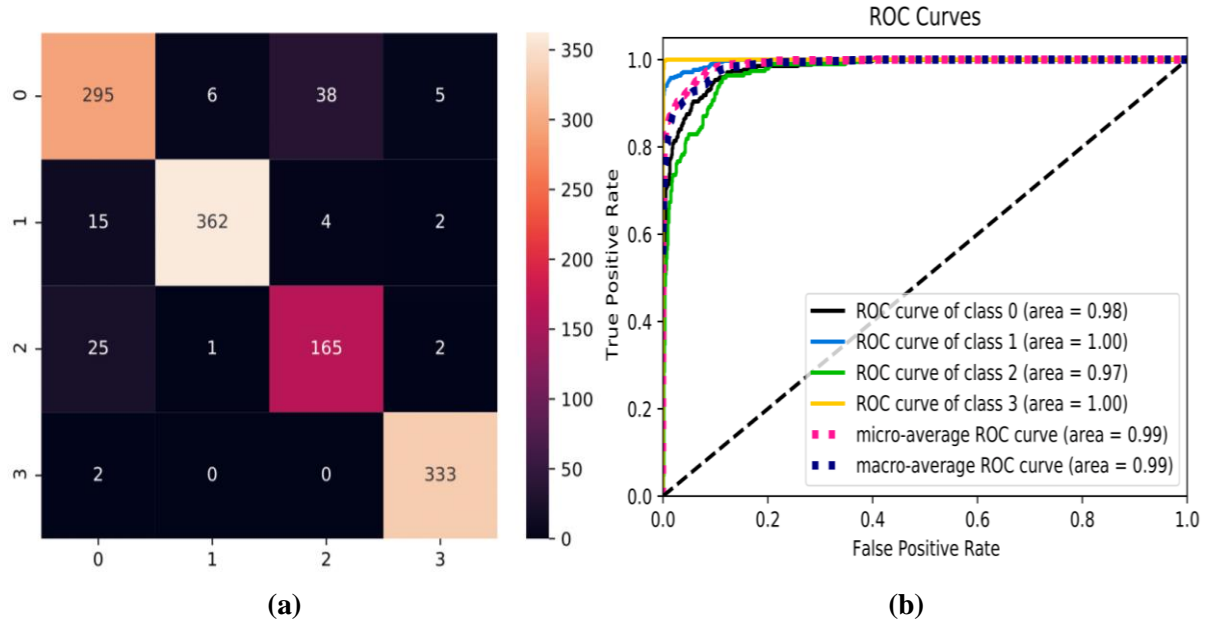
	Doğruluk (%)	Toplam yanlış sınıflandırma	Adım hızı - ms	Eğitim süresi-s	Çözünürlük piksel
Model-1	92.03	100	360	1800	400x400
Model -2	89.88	127	7	30	50x50

Tablo 2'de çalışmada kullanılan modellere ait sonuçlar görülmektedir. Model-1'de test verileri üzerinde %92.03 başarı oranıyla doğru tahmin yapıldığı görülmektedir. 1255 adet test verisi için 100 hatalı tahmin yapıldığı, adım hızı olarak 360 milisaniyede gerçekleştiği ve toplam eğitim süresinin 1800 saniye olduğu görülmektedir. Ayrıca EfficientNetB5'in yapısı gereği, giriş verisi olarak 400x400 piksel

görüntülerin kullanıldığı Tablo 2’de de gösterilmektedir. Model-2’de ise test verileri üzerindeki başarı oranı %89.88 olarak elde edilmiştir. Test verileri üzerinde 127 hatalı tahmin yapıldığı, adım hızı olarak 7 milisaniyede gerçekleştiği ve toplam eğitim süresinin 30 saniyede tamamlandığı görülmektedir.


4. Deneysel Çalışmalar

Bu bölümde, metot bölümünde açıklanan sınıflandırma modellerinin sınıflandırma sonuçlarına ait bulgular yer almaktadır. Makine öğrenmesi ile geliştirilen modellerin sınıflar arasındaki ayrımı ne kadar başarılı bir şekilde yapabildiğini belirleyebilen ROC (Receiver Operating Characteristic) eğrisi, karmaşıklık matrisi ve modellerin eğitim sırasındaki kayıpları ve başarılarını gösteren grafik ve görseller bu bölümde yer almaktadır.



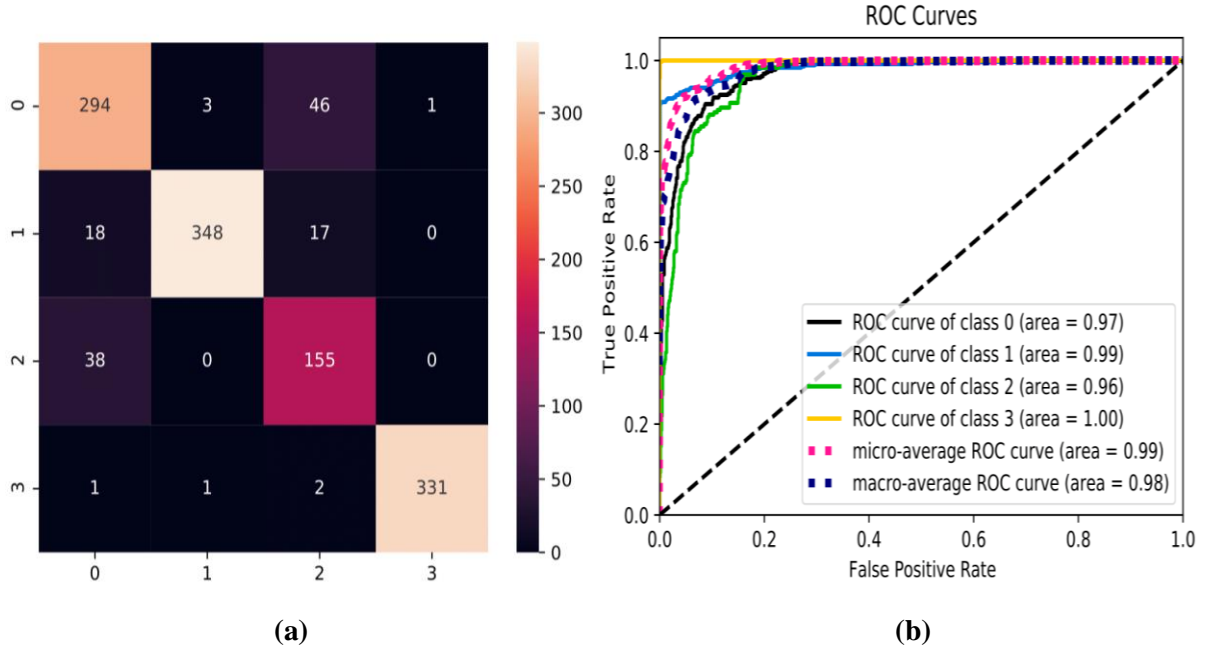
Şekil 3. Model-1’in karmaşıklık matrisi ve ROC eğrileri

Şekil 3.a’da verilen karmaşıklık matrisinde materyal bölümünde belirtilen 4 adet sınıfa (Şekil 3.a’da 0 mısır pası, 1 gri yaprak lekesi, 2 yaprak yanığı ve 3 normal sınıfına denk gelmektedir.) ait doğru ve hatalı tahmin bilgileri görülmektedir. Model-1’in karmaşıklık matrisi ve ROC eğrisi Şekil 3.a ve Şekil 3.b de gösterilmektedir. Şekil 3.a’da karmaşıklık matrisinde 0 numarasına karşılık gelen mısır pası hastalığının test verileri üzerinde geliştirilen Model-1 tarafından 295 doğru tahmin ve 49 hatalı tahmin yapıldığı görülmektedir. 1 numaraya karşılık gelen gri yaprak lekesi ise 362 doğru tahmin ve 21 hatalı tahmin, 2 numaraya karşılık gelen yaprak yanığı tahmininde ise 165 doğru ve 28 hatalı, 3 numaraya karşılık gelen normal yaprak (sağlıklı mısır yaprağı) tahmininde ise 333 doğru ve 2 hatalı tahmin yapıldığı görülmüştür. Şekil 3.b’de görülen ROC eğrisinin y eksenini, 4 sınıfa ait doğru pozitif değerlerini (Hassasiyet) gösteriyorken, x eksenini yanlış pozitif değerlerini göstermektedir. 4 sınıfa ait ROC eğrileri siyah, mavi, yeşil, sarı renkte verilmiştir. Bu eğrilerin altında kalan alana göre öğrenmenin başarı performansı yorumlanabilmektedir. Şekil 3.b’de en büyük alan sarı renkli eğrinin olduğu görülmektedir ve 3 numara ile belirtilen normal mısır yaprağına ait olduğu anlaşılmaktadır. Karmaşıklık matrisi değerlerinde de mısır yaprağına ait sınıflandırmanın model açısından en başarılı tahminler olduğu görülmektedir.



Şekil 4. Model-1'in eğitim başarımları ve kayıpları


Şekil 4.a-b'de, metot bölümünde açıklanan Model-1'e ait eğitim başarımları ve kayıpları gösterilmektedir. Şekil 4.a'da test ve eğitim başarımları verilmektedir. Grafikte mavi ile belirtilen eğri eğitim başarımlarını (training accuracy), turuncu renk ile gösterilen eğri ise test başarımlarını (val accuracy) göstermektedir. Şekil 4.a test ve eğitim başarımlarının 1'e veya %100'e yaklaştığını ve dolayısıyla eğitimin başarılı olduğunu gösterir. Şekil 4.b'de mavi ile belirtilen eğri eğitim kayıplarını (training loss), turuncu ile gösterilen eğri de test kayıplarını (val loss) göstermektedir. Şekil 4.b'de test ve eğitim kayıplarının 0 değerine yaklaştığı ve bu nedenle eğitimin başarılı olduğu söylenebilir.



Şekil 5. Model-2'nin karmaşıklık matrisi ve ROC eğrileri

Şekil 5.a'da görülen karmaşıklık matrisinde materyal bölümünde belirtilen 4 adet sınıfa (Şekil 5.a'da 0 mısırs pası, 1 gri yaprak lekesi, 2 yaprak yanığı ve 3 normal sınıfına denk gelmektedir) ait doğru ve hatalı tahminlere ait bilgiler yer almaktadır. Model-2'nin karmaşıklık matrisi ve ROC eğrisi Şekil 5.a

ve Şekil 5.b’de görülmektedir. Şekil 5.a da karmaşıklık matrisinde 0 numarasına karşılık gelen mısır pası hastalığının test verileri üzerinde geliştirilen model tarafından 294 doğru tahmin yaptığı 50 hatalı tahmin yaptığı görülmüştür. 1 numaraya karşılık gelen gri yaprak lekesi ise 348 doğru tahmin 35 hatalı tahmin yaptığı, 2 numaraya karşılık gelen yaprak yanığı tahmininde ise 155 doğru 38 hatalı,3 numaraya karşılık gelen normal yaprak(sağlıklı mısır yaprağı) tahmininde ise 331 doğru 4 hatalı tahmin yaptığı görülmüştür.



Şekil 6. Model-2'nin eğitim başarımları ve kayıpları

Şekil 6.a-b’de metot bölümünde açıklanan Model-2'nin eğitim başarımları ve kayıpları verilmiştir. Şekil 6.a, test ve eğitim başarımlarını göstermektedir. Aynı şekilde, grafikte mavi ile eğitim başarımları gösteriliyorken (training accuracy), turuncu renk ile test başarımları (val accuracy) verilmektedir. Şekil 6.a’da test ve eğitim başarımlarının 1 değerine yaklaştığı ve bu nedenle eğitimin başarılı olduğu söylenebilir. Şekil 6.b’de ise mavi ile eğitim kayıpları (training loss), turuncu renk ile de test kayıpları (val loss) gösterilir. Bu noktada, Şekil 6.b’de test ve eğitim kayıplarının 0’a yaklaştığı ve dolayısıyla eğitimin başarılı olduğu söylenebilir.

5. Sonuçlar

Bu çalışmada, mısırların yapraklarından belirlenebilen mısır pası, gri yaprak lekesi, yaprak yanığı ve normal (sağlıklı) yapraklı mısırların sınıflandırmasını yapan 2 adet derin öğrenme modeli geliştirilmiştir. Geliştirilen derin öğrenme modelleri Kaggle platformu üzerinde oluşturulmuştur. Çalışmada kullanılan veri seti Kaggle üzerinden alınarak modellerin eğitimi gerçekleştirilmiştir. Çalışmada geliştirilen modellere ait sınıflandırma performans metrikleri Tablo 3’te verilmiştir.

Tablo 3. Çalışmada kullanılan modeller için sınıflandırma performans metrikleri

	Model-1	Model -2
Doğruluk (%)	92.03	89.88
Hata (%)	7.97	10.12
Duyarlılık (%)	91.29	88.86
Özgüllük (%)	97.41	96.76
Kesinlik (%)	90.68	88.19
F ₁ Skoru (%)	90.95	85.19
MCC	0.8836	0.8519

Tablo 3'ten de görüldüğü gibi, bu çalışmanın metot bölümünde açıklanan Model-1'in başarısı %92.12 olarak bulunmuştur. Ayrıca, derin öğrenme katmanları kullanılarak oluşturulan Model-2'nin başarısının da %89.88'e eşit olduğu görülmektedir. İki model karşılaştırıldığında, transfer öğrenmesi ile oluşturulan Model-1 ve Model-2 arasında %2.24'lik bir fark olduğu görülmüştür. Sonuçlardan, Model-1 ve Model-2'nin doğruluğunun (%), hatasının (%), duyarlılığının (%), özgüllüğünün (%), kesinliğinin (%), F1 Skorunun (%) ve MCC'sinin (Matthews Correlation Coefficient) sırasıyla 92.03-7.97-91.29-97.41-90.68-90.95-90.65-0.8836 ve 89.88-10.12-88.86-96.76-88.19-85.19-0.8519'a eşit olduğu görülmektedir. Her iki model karşılaştırıldığında, Tablo 2'den de anlaşılacağı gibi Model-2'nin, Model-1'e göre daha hızlı çalıştığı ve daha küçük dosya boyutuna sahip olduğu görülmektedir.

Kaynakça

Priyadharshini, A., R., Arivazhagan, S., Arun, M., & Mirnalini, A. (2019). Maize leaf disease classification using deep convolutional neural networks. *Neural Computing and Applications*, 31(12), 8887–8895. <https://doi.org/10.1007/s00521-019-04228-3>.

Alkan, A., Abdullah, MU., Abdullah, H.O., Assaf, M., Zhou, H., (2021). A smart agricultural application: automated detection of diseases in vine leaves using hybrid deep learning, *Turkish Journal of Agriculture and Forestry*. doi:10.3906/tar-2007-105.

An, J., Li, W., Li, M., Cui, S., & Yue, H. (2019). Identification and classification of maize drought stress using deep convolutional neural network. *Symmetry*, 11(2), 1–14. <https://doi.org/10.3390/sym11020256>.

Aurangzeb, K., Akmal, F., Khan, A., M., Sharif, M., & Javed, M. Y. (2020). Advanced Machine Learning Algorithm Based System for Crops Leaf Diseases Recognition. *Proceedings - 2020 6th Conference on Data Science and Machine Learning Applications, CDMA 2020*, 146–151. <https://doi.org/10.1109/CDMA47397.2020.00031>.

Dataset, corn-or-maize-leaf-disease-dataset @ www.kaggle.com. (y.y.). Tarihinde adresinden erişildi <https://www.kaggle.com/smaranjitghose/corn-or-maize-leaf-disease-dataset>.

Huang, Z., Qin, A., Lu, J., Menon, A., & Gao, J. (2020). Grape Leaf Disease Detection and Classification Using Machine Learning. *Proceedings - IEEE Congress on Cybermatics: 2020 IEEE International Conferences on Internet of Things, iThings 2020, IEEE Green Computing and Communications, GreenCom 2020, IEEE Cyber, Physical and Social Computing, CPSCom 2020 and IEEE Smart Data, SmartData 2020*, (January), 870–877. <https://doi.org/10.1109/iThings-GreenCom-CPSCom-SmartData-Cybermatics50389.2020.00150>.

Kusumo, B. S., Heryana, A., Mahendra, O., & Pardede, H. F. (2019). Machine Learning-based for Automatic Detection of Corn-Plant Diseases Using Image Processing. *2018 International Conference*

on Computer, Control, Informatics and its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding, 93–97. <https://doi.org/10.1109/IC3INA.2018.8629507>.

Lv, M., Zhou, G., He, M., Chen, A., Zhang, W., & Hu, Y. (2020). Maize Leaf Disease Identification Based on Feature Enhancement and DMS-Robust Alexnet. *IEEE Access*, 8, 57952–57966. <https://doi.org/10.1109/ACCESS.2020.2982443>.

Sibiya, M., & Sumbwanyambe, M. (2019). A Computational Procedure for the Recognition and Classification of Maize Leaf Diseases Out of Healthy Leaves Using Convolutional Neural Networks. *AgriEngineering*, 1(1), 119–131. <https://doi.org/10.3390/agriengineering1010009>.

Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. 36th International Conference on Machine Learning, ICML 2019, 2019-June, 10691–10700.

Zhang, X., Qiao, Y., Meng, F., Fan, C., & Zhang, M. (2018). Identification of maize leaf diseases using improved deep convolutional neural networks. *IEEE Access*, 6, 30370–30377. <https://doi.org/10.1109/ACCESS.2018.2844405>.

Zhang, Z., He, X., Sun, X., Guo, L., Wang, J., & Wang, F. (2015). Image recognition of maize leaf disease based on GA-SVM. *Chemical Engineering Transactions*, 46, 199–204. <https://doi.org/10.3303/CET1546034>.

Zhao, Y.-X., Wang, K.-R., Bai, Z.-Y., Li, S.-K., Xie, R.-Z., & Gao, S.-J. (2009). Research of Maize Leaf Disease Identifying Models Based Image Recognition. *Crop Modeling and Decision Support*, 1(2004), 317–324. https://doi.org/10.1007/978-3-642-01132-0_35.