

## DOMATES HASTALIĞI TAHMİNİ İÇİN GERÇEK ZAMANLI UYGULAMA

Doğukan DEMİRCİ<sup>1</sup>, Esmenur SARAÇBAŞI<sup>2</sup>, Emre EMRAH<sup>3</sup>, İsmail UZUN<sup>4</sup>, Yakup GENÇ<sup>5</sup>, Kemal ÖZKAN<sup>6\*</sup>

<sup>1,2,3,4</sup> İNOSENS Bilişim Teknolojileri San. ve Tic. Ltd. Şti. GOSB Teknopark, Hightech Binası 1.Kat A8 41480 Gebze, Kocaeli

<sup>1</sup>ORCID No : <https://orcid.org/0000-0001-8422-4244>

<sup>2</sup>ORCID No : <https://orcid.org/0000-0001-9022-7476>

<sup>3</sup>ORCID No : <https://orcid.org/0000-0001-8422-4244>

<sup>4</sup>ORCID No : <https://orcid.org/0000-0002-1261-0856>

<sup>5</sup>Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kocaeli

ORCID No : <https://orcid.org/0000-0002-6952-6735>

<sup>6</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir

ORCID No : <https://orcid.org/0000-0003-2252-2128>

Anahtar Kelimeler	Öz
Domates hastalığı Mobil uygulama Resnet50	Hem ülkemizde hem de dünyada vazgeçilmez bir besin kaynağı olan domates bitkilerinde görülen hastalıkların önceden belirlenmesi önemlidir. Birçok domates hastalığının erken dönem belirtileri yapraklarda görülmektedir. Bu çalışmada literatürdeki standart veri setlerine ek olarak toplanan saha verileri kullanarak domates bitkisinde yaygın olan alternaria ve mildiyö hastalıklarının yaprak imgelerinden tespiti için bir yöntem geliştirilmiştir. Derin öğrenmede sıklıkla kullanılan Resnet50 mimarisi kullanılarak geliştirilen model bitki yaprak imgelerinden hastalıkları %97 doğrulukla belirlemektedir. Bazı hastalık belirtilerinin benzer olduğu düşünüldüğünde modelin hastalık belirtilerinin iyi ayırt ettiği görülmektedir. Modelin başarısında sahadan özel olarak bu amaçla toplanan verinin büyük katkısı vardır. Geliştirilen mimari mobil cihaza uygulanmış ve sonuçları çiftçilerle paylaşmıştır.

## REAL-TIME APPLICATION FOR TOMATO DISEASE PREDICTION

Keywords	Abstract
Tomato diseases Mobile application Resnet50	It is important to determine the diseases of the tomato plant, an essential food source both in our country and in the world. Most tomato disease shows early stage signs on the leaves. In this study, a method has been developed for the detection of common alternaria and mildew tomato diseases from plant leaf pictures using data collected in the field in addition to well known datasets in the literature. A model based on Resnet50 architecture, frequently used in deep learning, yields 97% accuracy in disease detection is achieved. Considering that some of the symptoms look similar, the model is able to distinguish relevant features. The data collected for disease detection purposes plays a crucial part in model accuracy. This architecture was applied to the mobile device and the results were shared with the farmers.

Araştırma Makalesi	Research Article
Başvuru Tarihi : 06.09.2021	Submission Date : 06.09.2021
Kabul Tarihi : 07.03.2022	Accepted Date : 07.03.2022


### 1. Giriş

Domates, Türkiye’de yaygın olarak ekilen önemli ürünlerden birisi olup, yenilebilirliği ve tıbbi değeri yüksektir. Domates yetiştirme sürecinde, ekim alanı ne kadar geniş olursa, büyük ölçekli hastalıklarla karşılaşma olasılığı da o kadar artar. Hastalık oluşması ciddi ekonomik kayıplara neden olmaktadır. Birçok

domates hastalıkları erken evrelerinde yapraklarda farklı semptom gösterebilen lezyonlara neden olur. Şu anda, Türkiye’deki domates hastalıklarını belirlemenin ana yöntemi genellikle çiftçilerin deneyimleriyle hastalıkların kaba bir tahmininin yapılmasıdır. Domates hastalıklarını sınıflandırmak için insan gücünün kullanıldığı emek süreci, sadece otomasyon eksikliği değil, aynı zamanda yorgunluk ve duygu gibi subjektif

\* Sorumlu yazar; e-posta: kozkan@ogu.edu.tr

faktörlerden etkilenir. Ayrıca hastalıklar ancak semptomlar ortaya çıktığında tespit edilebilir. Bu nedenle domates yapraklarının hastalıklarının hızlı ve doğru bir şekilde nasıl tespit edileceği ve uygun kontrol önlemlerinin nasıl alınacağı domates bitkilerinin etkin üretiminin sağlanması açısından önem taşımaktadır. Domates yaprağı hastalığını erken dönemde teşhis etmek için geleneksel yöntemlerde genel öznelıklar kullanılır (renk, doku, şekil vb.). Bu genel özellikler ile bitki yaprak hastalığında hastalık lekelerinin özelliklerini tanımlamak için görüntüler, hastalıklı kısım ve domates yaprağının normal kısmı değerlendirme yöntemi ile ayrılmış ve ölçüt olarak iki parçanın alan oranı hesaplanmıştır (Tao, Zhao, Xi, Yu ve Wang, 2014). Derin öğrenmenin gelişmesiyle birlikte, geleneksel yöntemlere göre öznelik çıkarma ve tanımda bariz avantajlar ortaya çıkmıştır. Örneğin, Evrişimli Sinir Ağları (ESA), yerel bağlantı ve ağırlık paylaşımı vb. sunarak veri özelliklerini çıkarmak için ağı otomatik olarak eğitir. Bu yöntemler muz, salatalık ve domates hastalıklarının tanımlanmasında başarılı şekilde uygulanmıştır (Srdjan, Marko, Andras, Dubravko ve Darko, 2016; Zhou, Zhang, Chen ve He, 2019). Ancak farklı tanıma modellerinin yapı farklılığı ve doğal ortamın domates yapraklarının görüntüsüne etkisi başarıyı etkilemektedir. Bu nedenle, bu çalışmada ele alınan ana problemler şunlardır: (1) Domates yaprağının orijinal veri seti doğrudan ağa girdiğinde, ESA yapısı özellikleri eğitim setinden otomatik olarak öğrenebilir, ancak domates yapraklarının orijinal görüntüsündeki arka plan, gürültü ve hastalıklı bölgeyi



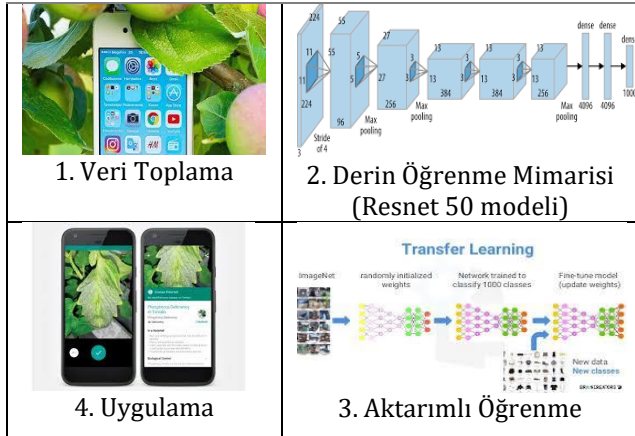
Şekil 1. Yaprak imgesinden hastalık teşhisinin zorlukları: (a) arka planın düzenli olmaması, (b) birden fazla hastalığa sahip yaprak, (c) hastalık alanının küçük olduğu yaprak, (d) çiftçi tarafından çekilen fotoğrafın görüntü işlemeye uygun olmaması ve (e) tamamen çürümüş yaprakların ayırt edici semptom içermemesi

belirleyecek özellikleri yine de yanlış özellik çıkarımına yol açabilir. (2) Ağ modelinin ayarlanması ile domates

yaprak hastalıkları bazı kategoriler (hastalıklar) arasında büyük benzerlik göstermektedir ki bu da yapay sinir ağıyla ayırt edilmesini zorlaştırır. Aynı hastalığın erken ve geç görüntü özellikleri oldukça farklıdır. Özellikle hastalığın erken evresinde hastalıklı alan küçüktür, semptomlar belirgin değildir ve ağ katmanlarından daha detaylı özelliklerin çıkarılması gerekir. Ayrıca bazı durumlarda aynı yaprakta birden fazla hastalık oluşabilmektedir. (3) Veri seti, doğal çevre ve diğer faktörler nedeniyle yeterli olmayabilir. Gerçek zaman uygulamalarında karşılaşılan zorluklar Şekil 1'de resmedilmiştir.

## 2. Bilimsel Yayın Taraması

Tarımsal ürünlerin imge kullanarak tanıma işlemleri son 20 yıldır hızlı bir şekilde artmıştır. Örneğin, Cui, Cheng, Dong, Liu ve Wang (2005) domates bitkisi hastalıklı yaprak görüntülerindeki renk ve doku bilgilerinden elde ettikleri özellik parametrelerini k-en yakın komşu sınıflandırıcı kullanılarak hastalık tespiti gerçekleştirmişlerdir. Geleneksel yöntem olarak isimlendirilen bu tür yaklaşımlarda tanımanın doğruluğu, özellik parametrelerinin seçiminden etkilenir. Son yıllarda seçilmesi gereken parametreleri öğrenme oranını çıktı hatasına göre dinamik olarak ayarlama ve probleme özgü model oluşturma tercih edilmeye başlanmıştır (Zhang, Lai Jing ve Lv, 2015). Örneğin, Zhang vd. (2018), bölge tabanlı evrişimli sinir ağı oluşturmak için Görsel Geometri Grubu (VGG) tarafından geliştirilen derin öğrenme mimarisi kullanarak özellikleri çıkarıcı ve yaprak hastalığı tanıma için uçtan uca derin öğrenme mimarisi sunmuşlardır. Rangarajan, Purushothaman ve Ramesh (2018) derin öğrenme ve bitki hastalıkları araştırmalarında son teknoloji model AlexNet ve VGG16 ile transfer öğrenmeyi başarılı şekilde uygulamışlardır. Derin öğrenme modelleri, tahminleri doğru bir şekilde modelleyebilmek için tipik olarak çok fazla sayıda veriye ihtiyaç duymaktadır. PlantVillage (2018) veri kümesinin kullanıma sunulmasına kadar yalnızca az veriye sahip hastalıklı veri kümeleri bulunmaktaydı (Hughes ve Salathe, 2015). Bu veri setinin yayınlanmasından sonra çalışmalar hız kazanmıştır. Bu veri setini kullanan, Brahimi vd. (2018), AlexNet ve GoogleNet gibi klasik modellerden transfer öğrenimi kullanılarak on domates hastalığı için sınıflandırma modelleri sunmuştur. Brahimi vd. (2018) PlantVillage veri kümesinin ImageNet veri kümesiyle eğitilen modelin iyileştirilmesinin sıfırdan model eğitiminden daha iyi olduğunu belirtmiştir. Kumar ve Vani'nin çalışmasında (2019), donanım uygulamaları söz konusu olduğunda, ResNet ve Xception mimarilerinin önceki yılların mimarilerine göre daha iyi sonuçlarla kullanıldığı gösterilmiştir. Sibiya ve Sumbwanyambe (2019) cep telefonu ile çekilen hastalıklı görüntülerin tanımlanması



Şekil 2. Önerilen yöntemin ana aşamaları: Toplanan veriler bir derin ağı eğitilmesinde kullanılmış ve sonuç model bir mobil uygulamaya uyarlanmıştır

ve sınıflandırılması için ESA uygulamış ve doğrulukta ortalama %92,85'e ulaşmışlardır. Durmuş, Güneş ve Kırıcı (2017), AlexNet ve SqueezeNet evrişim ağını sağlıklı bitkilere ait görüntüler de dahil olmak üzere 10 çeşit domates yaprağını eğitmek için kullanmışlardır. Çalışma sonucunda derin evrişim ağına performansının sığ ağdan daha iyi olduğu, model parametrelerinin ön-eğitim ağırlığı model performansını artırdığı ve bu temelde domates yapraklarının hastalık bölgeleri belirlendiği belirtilmiştir. Bununla birlikte, ağ katmanı çok derin olduğunda gradyan kaybolması veya gradyan patlaması meydana gelecektir ve ağı domates yaprağı hastalıklarına benzer problemlerde başarı oranı azalabilmektedir.

### 3. Yöntem

Geleneksel RGB kameralarla görüntülenen görünür özellikleri kullanan çalışmalarda, makine öğrenimi sistemleri yerine, derin evrişimli sinir ağı modelleri son yıllarda sıklıkla kullanılmıştır (Mohanty, Hughes ve Salathe, 2016; Alfarişy, Chen ve Guo, 2018). Bu çalışmada sırasıyla ilk olarak kullanılan veri seti ve bunların veri artırma yoluyla modifikasyonları verilmiş, burada veri setine yerel dönüşümler yapılmış, daha sonra kullanılan CNN mimariler eğitim aşaması için önerilen hiper parametreler açıklanmış, ardından elde edilen sonuçların performans kriterleri sunulmuştur. Son olarak elde edilen sonuçların cep telefonunda kullanılması için bir GUI tasarımı gerçekleştirilmiştir. Önerilen modelin blok diyagramı aşamalar halinde Şekil 2'de sunulmuştur. Bu çalışmada araştırma ve yayın etiğine uyulmuştur.

### 3.1. Veri

Bu çalışmada domates için belirlenen alterna ve mildiyö hastalıklarını sınıflandırmak amacıyla ESA modelleri kullanılmıştır. Kullanılan bu modellerin başarı oranlarının artması amacıyla aktarımlı öğrenmeden

Tablo 1

Çalışmada Kullanılan Domates İmgeleri (Saha Verisi ve PlantVillage)


Kullanım	Hastalık	Sayı
Eğitim (%70)	alternaria	1558
	mildiyö	1558
Doğrulama (%15)	alternaria	334
	mildiyö	334
Test (%15)	alternaria	334
	mildiyö	334

yararlanılmıştır. Çalışmada kullanılan domates imgeleri Tablo1 ve Şekil 3 de verilmiştir. Sık uygulanan bir düzenleme tekniği olan veri artırımı da bu çalışmada da uygulanmıştır. Veri artırımı için geniş bir rotasyon (0-360), geometrik distorsiyon ve gürültü uygulanmıştır. Özellikle distorsiyon seçiminde yaprak ve kamera olası açıları dikkate alınarak geniş bir spektrumda distorsiyon oluşturulmuştur.

### 3.2. Model

Bu çalışmada domates için belirlenen alterna ve mildiyö hastalıklarını sınıflandırmak amacıyla ESA modelleri kullanılmıştır. Kullanılan bu modellerin başarı oranlarının artması amacıyla aktarımlı öğrenmeden yararlanılmıştır. Bu kapsamda denenen çeşitli modeller sırasıyla InceptionV3, VGG16, ResNet50 ve MobilNetV2'dir. Bunlar arasında hem test hem de doğrulama başarımları en yüksek olan Resnet50 modeli olmuştur (Şekil 4). Resnet50 modeli için hiper parametreleri Tablo 2'de verilmiştir.

Derin öğrenme modeli olarak imge işlemede çok başarılı olarak kullanılan ResNet50 modeli kullanılmıştır. ResNet mimarisi doğrudan bağlantılar yoluyla katmanlar arasındaki öznelikleri daha etkin kullanabilen ve regularizasyon sağlayan bir yöntemdir (He, Zhang, Ren ve Sun, 2016). Bu tür bir model zengin bir veri seti gerektirdiği için genellikle aktarımlı öğrenme ile birleştirilir. ImageNet ile eğitilmiş model çalışmadaki veri setinde rafine edilmek için tekrar eğitilmiştir. Bu aktarımlı öğrenmede bütün katmanlar eğitime sokulmaktadır. Son olarak veri seti hala model için çok büyük olduğu için erken durma yöntemi (200 epok) de uygulanmıştır.



Şekil 3. Çalışmada kullanılan domates imgelerin dağılımı

Tablo 2

Resnet50 Modelinin Hiper Parametreleri

Kullanılan Hiper Parametreler	Değerler
Eniyileme	Adam
Öğrenme Oranı	1e-4
Kayıp Fonksiyonu	binary_crossentropy

#### 4. Bulgular

Önerilen yöntemin başarımı için literatürde sıklıkla kullanılan aşağıda verilen karşılaştırma yöntemleri kullanılmıştır.

**Doğruluk:** Bir modelin verimliliğini değerlendirmek için ana kriterdir. Daha iyi bir model, diğer modelden daha yüksek doğruluğa sahip olacaktır. Doğruluk değeri, Denklem 1 kullanılarak hesaplanır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Burada; DP-Doğru Pozitif, DN-Doğru Negatif, YP-Yanlış Pozitif, YN-Yanlış Negatif ifade etmektedir.

**F1-skor:** Aynı zamanda, farklı öğrenme yöntemlerinin karşılaştırıldığı popüler bir performans değerlendirme yöntemidir ve duyarlılık ve kesinliğin harmonik ortalamasıdır. F1 skoru Denklem 2 kullanılarak hesaplanır.

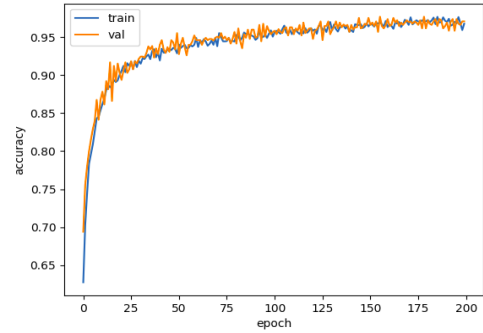
$$F1 = \frac{2 * \text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2)$$

Kesinlik ve duyarlılık denklemleri (3) ve (4)'de verilmiştir.


$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4)$$

Yapay sinir ağlarında bütün eğitim verisinin bir defa eğitimde kullanılması epok olarak nitelenir. Model eğitim sırasında her epok için özellikle doğruluğun ve kullanılan kayıp fonksiyonunun değeri de bir grafik olarak sunulur. Önerilen modelin çeşitli aşamalarında elde edilen doğruluk ve hata değerleri Şekil 4'de hem eğitim hem de validasyon verileri için gösterilmektedir. Görüldüğü gibi epok sayısı arttıkça test doğruluğu artmakta ve en iyi performans 200 epok'da elde edilmekte (maksimum %97 doğruluk), ardından performans düşmeye başlamaktadır. Bu performans



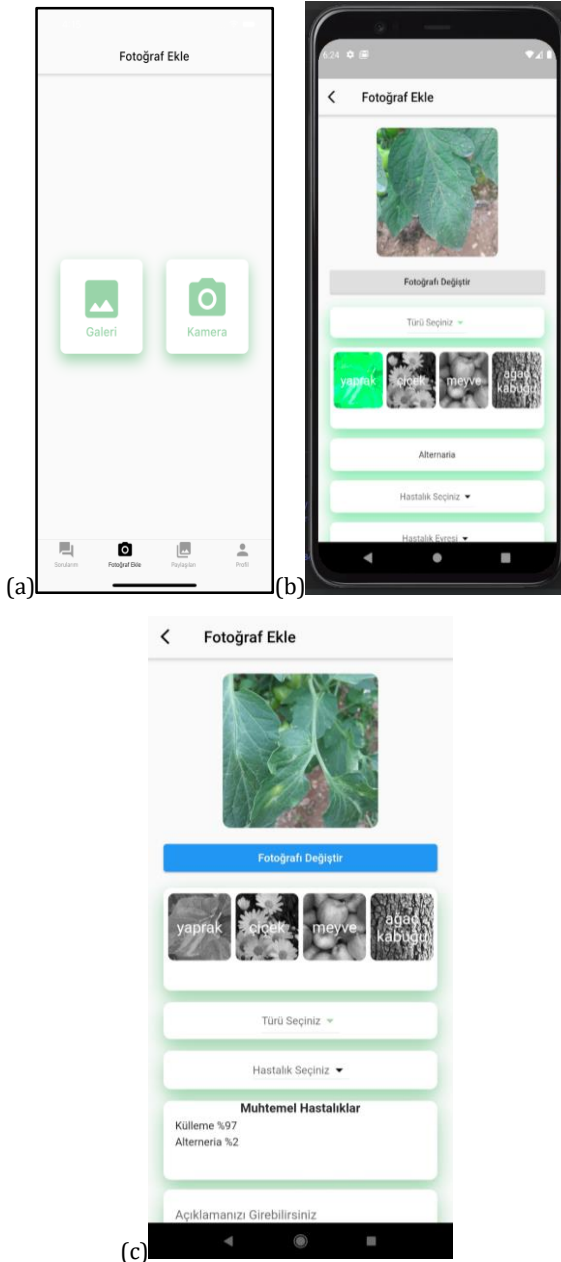
Şekil 4. Resnet50 Model Doğruluk Grafiği



Şekil 5. Resnet50 Model Kayıp Grafiği

düşüşü genel olarak modelin aşırı öğrendiğine işaret etmektedir (Tablo 3). Bireysel hastalık sınıfları için performans, Tablo 4'teki karşıtlık matrisinde gösterilmektedir. Bu matriste, köşegen öğeler doğru tahminleri gösterirken, kalan öğeler yanlış sınıflandırmaları gösterir. Örneğin, karşıtlık matrisinin ilk satırında, 312 test imgesinin 308'i doğru bir şekilde alternaria olarak sınıflandırılmış ve sadece 4 imge hatalı olarak (mildiyö) yanlış sınıflandırılmıştır. Matristen,

önerilen modelinin çoğu hastalık sınıfında doğru tahminler yapabildiği açıktır. Model oluşturulduktan sonra, mobil uygulamaya entegrasyon kısmı geliştirilmiştir. Bitkide hangi hastalık olduğunun tahminini görmek isteyen üreticinin önceden çektiği veya o anda mobil cihazından çekebileceği bir imgenin yüklenmesi istenir. Yüklenen imgenin hastalık tahmini sonucu ekranın alt tarafında gözükür (Şekil 6).



Şekil 6. Örnek mobil uygulama: (a) uygulama başlangıç ekranı, (b) fotoğraf ekleme, ve (c) tespit sonucu

## 5. Tartışma

Eğitim için hazır olan veri sayısı az olduğu durumlarda geleneksel makine öğrenmesi teknikleri başarıya ulaşsa da veri boyutu arttıkça derin öğrenme yaklaşımlarının geleneksel makine öğrenimi tekniklerinden daha iyi performans gösterdiği yapılan çalışmalarla kanıtlanmıştır. Diğer taraftan, aktarımlı öğrenme ile öznelik çıkarımı çok verinin olduğu bir problemde yapılırken, az verinin olduğu bir probleme hazır model kullanarak başlamak geleneksel yöntemlerden daha iyi sonuç vermektedir. Bu nedenle, önerilen derin öğrenme

Tablo 3

Resnet50 Model Başarımı

	Kesinlik	Duyarlılık	F1	Dayanak
alternaria	0.95	0.99	0.97	312
mildiyö	0.99	0.96	0.97	355
ortalama	0.97	0.97	0.97	667
ağırlıklı ortalama	0.97	0.97	0.97	667

mimarisi, yaprak görüntülerinden bitki hastalığı sınıflandırması için başarılı sonuçlar üretmektedir. Eniyileme yanında verinin hatasız olması ve az da olsa gerçek veri dağılımını dengeli yansıtmaları önemlidir. Bu çalışmada veri çok olmasa da dikkatli toplanmış ve artırılmış eğitimle son yıllarda başarılı olan derin öğrenme mimarileri probleme etkin olarak uygulanmıştır.

Tablo 4

Resnet50 Model Başarımı Karşıtlık Matrisi

Doğru \ Tahmin	alternaria	mildiyö
alternaria	308	4
mildiyö	15	340

## 6. Sonuçlar

Bu çalışmada, domates bitkilerinde 2 tür hastalığın sınıflandırılması için diğer alternatiflerine görece hafif bir Evrişimli Sinir Ağı modeli geliştirilmiştir. Deneysel amaçla, sahadan toplanan ve hastalık dağılımını dengeli sayıya az da olsa iyi sergileyen veriler kullanılmıştır. Başarımı arttırmak amacıyla veri artırma teknikleri ile verilerin çoğaltılması yapılmıştır. Deneysel sonuçlar önerilen algoritmanın başarımını göstermektedir. Önerilen algoritmanın performansı, karşıtlık matrisi, doğruluk, kesinlik, geri çağırma, F1 skoru, vb. gibi çeşitli değerlendirme ölçütlerine göre karşılaştırılmıştır. Önerilen algoritma ile %97 gibi yüksek bir başarımla elde edilmiştir. Gelecekteki çalışma olarak domates

bitkilerinde hastalığın şiddetinin tespit edilmesi amaçlanmaktadır. Önerilen çalışma, hastalığın bitkide ne ölçüde yayıldığını göstermek için de genişletilebilir. Bununla beraber önerilen çalışma geliştirilerek, bitki büyümesinin herhangi bir belirli aşamasında ihtiyaç duyulan ilaç miktarını belirlemede yardımcı olabilir.

### Teşekkür

Bu çalışma TÜRKİYE BİLİMSEL VE TEKNOLOJİK ARAŞTIRMA KURUMU (TÜBİTAK TEYDEB) tarafından 3191179 proje kapsamında desteklenmiştir. Çalışmada kullanılan mobil uygulama <https://play.google.com/store/apps/details?id=com.hiddenslate.mobiltarim> adresinden indirilebilir.

### Araştırmacıların Katkısı

Bu araştırmada; Doğukan DEMİRCİ ve Esmanur SARAÇBAŞI verilerin toplanması ve önışlemlerden geçirilmesin ve bilgisayara ortamına aktarılması; Emre EMRAH gerekli olan yazılımların gerçekleştirilmesinde, İsmail UZUN, Yakup GENÇ, Kemal ÖZKAN bilimsel yayın araştırması, makalenin oluşturulması, istatistiki analizler, makalenin sonuçların hazırlanması konularında katkı sağlamışlardır.

### Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

### Kaynaklar

- Alfarisy, A.A., Chen, Q. & Guo, M. (2018). Deep Learning based classification for paddy pests & diseases recognition. *In: Proceedings of 2018 International Conference on Mathematics and Artificial Intelligence, ICMAI '18*, 21–25, New York/USA. <https://doi.org/10.1145/3208788.3208795>
- Brahimi, M., Arsenovic, M., Laraba, S., Sladojevic, S., Boukhalfa, K. & Moussaoui, A. (2018). Deep Learning for Plant Diseases: Detection and Saliency Map Visualisation. *Human and Machine Learning*. Springer. [https://doi.org/10.1007/978-3-319-90403-0\\_6](https://doi.org/10.1007/978-3-319-90403-0_6)
- Cui, Y.L., Cheng, P.F., Dong, X.Z., Liu, Z.H. & Wang, S. (2005). Image processing and extracting color features of greenhouse diseased leaf. *Transaction of the Chinese Society of Agriculture Engineering* 21 (S2), 32–35.
- Durmuş, H., Güneş, E.O. & Kırıcı, M., 2017. Disease detection on the leaves of the tomato plants by using deep learning. *In: 2017 6th International Conference on Agro-Geoinformatics*, 1-5, Fairfax, USA. <https://ieeexplore.ieee.org/abstract/document/8047016>

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). [https://openaccess.thecvf.com/content\\_cvpr\\_2016/html/He\\_Deep\\_Residual\\_Learning\\_CVPR\\_2016\\_paper.html](https://openaccess.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html)
- Hughes, D.P. & Salathe, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics, arXiv:1511.08060
- Kumar, A. & Vani, M. (2019). Image based tomato leaf disease detection. *In: 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. 1–6, Kanpu, India. <https://doi.org/10.1109/ICCCNT45670.2019.8944692>
- Mohanty, S.P., Hughes, D.P. & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. doi: <http://dx.doi.org/10.3389/fpls.2016.01419>
- PlantVillage Dataset, 2018, <https://www.kaggle.com/emmarex/plantdisease>
- Rangarajan, A.K., Purushothaman, R. & Ramesh, A. (2018). Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Computer Science*, 133, 1040–1047. <https://doi.org/10.1016/j.procs.2018.07.070>.
- 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. *Agricultural Engineering*, 1, 119–131. <http://dx.doi.org/10.20944/preprints201902.0203>
- Srdjan, S., Marko, A., Andras, A., Dubravko, C. & Darko, S. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 1–11. <https://doi.org/10.1155/2016/3289801>.
- Tao, H.W., Zhao, L., Xi, J., Yu, L. & Wang, T. (2014). Fruits and vegetables recognition based on color and texture features. *Transaction of the Chinese Society of Agriculture Engineering*, 30 (16), 305–311. <https://doi.org/10.3969/j.issn.1002-6819.2014.16.039>
- Zhou, G.X., Zhang, W.Z., Chen, A.B., He & M.F. (2019). Rapid detection of rice disease based on FCM-KM and Faster R-CNN fusion. *IEEE Access*, 7, 143190–143206. <https://doi.org/10.1109/ACCESS.2019.2943454>
- Zhang, J.H., Kong, F.T., Wu, J., Zhai, Z., Wu, S. & Cao, S. (2018). Cotton disease identification model based on improved VGG convolutional neural network. *Journal of China Agriculture University*, 23 (11), 161–171.
- Zhang, Y.L., Lai, Z.Y., Jing, X. & Lv, J. (2015). Soybean disease detection based on improved BP neural network. *Journal of Agricultural Mechanization Research*, 2, 79–82.