



The performance comparison of pre-trained networks with the proposed lightweight convolutional neural network for disease detection in tomato leaves

İrem Nur Ecemiş^{1*}, Hamza Osman İlhan²

¹Department of Computer Engineering, Uluyazi Campus, Faculty of Engineering, Cankiri Karatekin University, 18100, Cankiri Türkiye

²Department of Computer Engineering, Faculty of Electrical and Electronics, Yıldız Technical University, Davutpasa Street, 34220, İstanbul, Türkiye

Highlights:

- Special CNN design especially for tomato leaf disease detection is presented.
- The proposed model uses low system resources and giving high classification performance in shorter training times.
- A comprehensive comparison of pre-trained networks with the proposed CNN architecture is given

Keywords:

- Tomato Leaf Disease Detection
- Convolutional Neural Networks
- Transfer Learning
- Data Augmentation
- Leaf Classification

Article Info:

Research Article

Received: 02.10.2021

Accepted: 20.03.2022

DOI:

10.17341/gazimmfd.1003730

Correspondence:

Author: İrem Nur Ecemiş

e-mail:

iremnurecemis@karatekin.edu.tr

phone: +90 534 556 6214

Graphical/Tabular Abstract

In this study, a CNN model named "T-LeafNet" is recommended to detect 9 different diseases on tomato leaves rapidly. Classification success was measured by training the proposed network from scratch. Network models within the scope of transfer learning - AlexNet, MobileNetV2, VGG16 - were tested on the dataset, and the results were compared with the proposed network (Figure A).

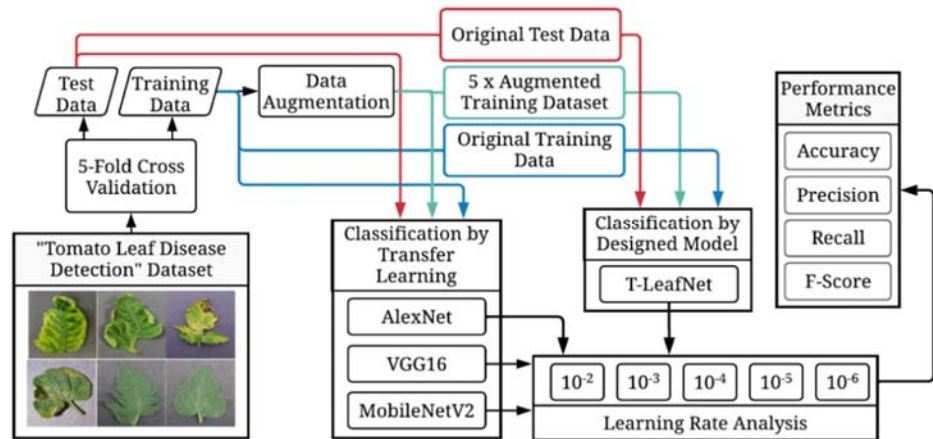


Figure A. The Flowchart of the Study

Purpose: Most of the diseases in tomatoes can be determined by observing the leaves. Therefore, the observation of tomato leaves is of critical importance in vegetable cultivation. Since preserving the health of the leaves will increase the productivity of tomatoes, it is a necessity to observe the leaf development and to determine the possible disease risks accurately and quickly in advance. The main purpose of the study is to create a CNN network to automatically determine the diseases in tomatoes using the only leaf images.

Theory and Methods: In the proposed study, the "T-LeafNet" Convolutional Neural Network model, which can detect 9 different diseases and healthy leaves in the leaves of tomato plants, is proposed. Classification success was measured by training the proposed network from scratch. In addition, within the scope of transfer learning, MobileNetV2, AlexNet and VGG16 architectures, which are ready-made network models, were also tested on the dataset and the results were compared. The effects of data augmentation and learning coefficient parameters on the achievement were also examined by applying the tests on the original and augmented data with different learning coefficients.

Results: The highest classification performances of T-LeafNet, AlexNet, MobileNetV2 and VGG16 networks were measured as 97.32%, 98.32%, 99.1% and 99.21%. Considering the training time and classification performances, it has been observed that the proposed T-LeafNet network gives high performance with shorter time and less resources compared to other tested networks.

Conclusion: Contrary to the long training times and high resource usage of pre-trained CNNs, a CNN architecture especially for tomato leaves, which is using low system resources and giving high classification performance in shorter training times is presented. The use of fewer layers in the design of the model made the model applicable for use on mobile platforms. After the implementation of the model in mobile platforms, the proposed model can be used by tomato growers to detect disease more easily.



Domates yapraklarında hastalık tespiti için önerilen hafif evrişimli sinir ağı ile önceden eğitilmiş ağların performans karşılaştırması

İrem Nur Ecemiş^{1*}, Hamza Osman İlhan²

¹Çankırı Karatekin Üniversitesi, Uluyazı Kampüsü, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 18100, Merkez Çankırı, Türkiye

²Yıldız Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, Davutpaşa Caddesi 34220, Esenler, İstanbul, Türkiye

ÖNEÇIKANLAR

- Özellikle domates yaprak hastalık tespiti için özel ESA tasarımı sunulmaktadır
- Önerilen model, düşük sistem kaynakları kullanır ve daha kısa eğitim sürelerinde yüksek sınıflandırma performansı verir
- Önerilen ESA mimarisi ile önceden eğitilmiş ağların kapsamlı bir karşılaştırması verilmektedir

Makale Bilgileri

Araştırma Makalesi

Geliş: 02.10.2021

Kabul: 20.03.2022

DOI:

10.17341/gazimmfd.1003730

Anahtar Kelimeler:

Domates yaprağı hastalık tespiti,
evrişimli sinir ağları,
öğrenme aktarımı,
veri artırma,
yaprak sınıflandırması

ÖZ

Domateslerde oluşan hastalıkların çoğu yaprakların gözlemlenmesi ile belirlenebilir. Bu nedenle domates yapraklarının gözlemlenmesi, sebze yetiştiriciliğinde kritik bir öneme sahiptir. Yaprakların üzerinde bulunan izler, renk değişimleri, kıvrıklık vb. hastalığı ya da hastalık riski oluşturabilecek bir virüsü işaret edebilir. Yaprakların sağlığının korunması domateslerin de verimliliğini artıracığından, yaprak gelişimlerinin gözlemlenmesi, olası hastalık risklerinin önceden doğru ve hızlı tespitinin yapılması bir gerekliliktir. Önerilen çalışmada, domates bitkisinin yapraklarında oluşan 9 farklı hastalığı ve sağlıklı yaprakları tespit edebilen "T-LeafNet" Evrişimsel Sinir Ağı (ESA-CNN) modeli önerilmiştir. Önerilen ağ sıfırdan eğitilerek sınıflandırma başarısı ölçülmüştür. Ayrıca, öğrenme aktarımı (transfer learning) kapsamında hazır ağ modellerinden MobileNetV2, AlexNet ve VGG16 mimarileri de veri kümesi üzerinde test edilmiş ve sonuçlar karşılaştırılmıştır. Testler orijinal ve artırılmış veriler üzerinde farklı öğrenme katsayıları ile uygulanarak, veri artırma ve öğrenme katsayı parametresinin başarıma etkisi de incelenmiştir. T-LeafNet, AlexNet, MobileNetV2 ve VGG16 ağlarının en yüksek sınıflandırma performansları %97,32, %98,32, %99,1 ve %99,21 olarak ölçülmüştür. Eğitim zamanı ve sınıflandırma performansları göz önünde bulundurulduğunda, önerilen T-LeafNet ağının, test edilen diğer ağlara kıyasen daha kısa süre ve az kaynakla, yüksek performans verdiği gözlemlenmiştir.

The performance comparison of pre-trained networks with the proposed lightweight convolutional neural network for disease detection in tomato leaves

HIGHLIGHTS

- Special CNN design especially for tomato leaf disease detection is presented
- The proposed model uses low system resources and giving high classification performance in shorter training times
- A comprehensive comparison of pre-trained networks with the proposed CNN architecture is given

Article Info

Research Article

Received: 02.10.2021

Accepted: 20.03.2022

DOI:

10.17341/gazimmfd.1003730

Keywords:

Tomato leaf disease detection,
convolutional neural networks,
transfer learning,
data augmentation,
leaf classification

ABSTRACT

Most of the diseases in tomatoes can be determined by observing the leaves. Therefore, the observation of tomato leaves is of critical importance in vegetable cultivation. Traces on the leaves, color changes, curling, etc. may indicate a disease or a virus that may pose a risk of disease. Since preserving the health of the leaves will increase the productivity of tomatoes, it is a necessity to observe the leaf development and to determine the possible disease risks accurately and quickly in advance. In the proposed study, the "T-LeafNet" Convolutional Neural Network (ESA-CNN) model, which can detect 9 different diseases and healthy leaves in the leaves of tomato plants, is proposed. Classification success was measured by training the proposed network from scratch. In addition, within the scope of transfer learning, MobileNetV2, AlexNet and VGG16 architectures, which are ready-made network models, were also tested on the dataset and the results were compared. The effects of data augmentation and learning coefficient parameters on the achievement were also examined by applying the tests on the original and augmented data with different learning coefficients. The highest classification performances of T-LeafNet, AlexNet, MobileNetV2 and VGG16 networks were measured as 97.32%, 98.32%, 99.1% and 99.21%. Considering the training time and classification performances, it has been observed that the proposed T-LeafNet network gives high performance with shorter time and less resources compared to other tested networks.

1. Giriş (Introduction)

Tarım, insanların en büyük geçim kaynaklarından biridir. Türkiye, sahip olduğu ekolojik ve coğrafik imkanlar sayesinde birçok tarımsal ürünü yetiştirmeye uygundur. Domates tarımında da dünya üretim skalasında önemli bir yere sahiptir. Domates, ketçap ve salça gibi birçok ana gıdada kullanıldığı ve Betakaroten, E vitamini, C vitamini ve potasyum gibi sağlığa çok faydalı besin değerleri içerdiği için dünyada en çok tüketilen sebzeler arasındadır. Türkiye de yılda 12,8 milyon tonluk domates üretimiyle dünyada üçüncü sırada ve domates ihracatında ise dünyada beşinci sırada yer almaktadır [1].

Bitki örtüsüyle birlikte iklim koşullarının uygunluğu domatesin yetiştirilmesinde çok büyük bir önem taşımaktadır. Ayrıca, domateslerin yapısal hassaslıklarından ötürü iklim ve bulunulan bölge kadar yetiştirilme koşullarına da dikkat edilmelidir. Açıkta ve örtü altında yapılan domates yetiştiriciliğinde birçok faktör domatesler üzerinde hasara ve bitkisel hastalıklara sebep olmaktadır. Bu hastalıklar, temelde bitkilerin fiziksel ve kimyasal yapılarını bozarak bitkinin gelişimini engellemektedirler. Farklı dış ve iç etkenlerin sebep olduğu hastalıklar %10 ile %30 arasında mahsul kaybına yol açmaktadır. Verilen oran yetiştiricilikte verimlilik düzeyi olarak nitelendirilen oranı doğrudan etkileyen yüksek bir değer olduğu için hastalıkların ilerlemeden ve diğer bitkilere bulaşmadan tespit edilmesi ve ardından gerekli müdahaleler yapılarak verimin artırılması gerekmektedir. Hastalıkların doğru ve erken teşhis edilmesi, üretim verimliliğinin artırılması için doğru müdahalenin belirlenmesini sağlayacaktır. Bu amaçla yetiştirilen bitkisel ürünlerdeki verimsizliği ve bitki kayıplarını önleyebilmek amacıyla ekildiği andan itibaren tüm büyüme aşamalarının özenle ve dikkatli incelenerek kaydedilmesi önemlidir. Domates yaprakları da hastalık tespiti için kullanılabilen ve en doğru sonuçları veren yapılardır. Ancak tüm bitkilerin tek tek kontrol edilmesi imkansızdır. Yetiştirilen domates yapraklarının üreticiler tarafından gözlemlenerek analiz edilmesi ve hastalık bazında sınıflandırılması zaman ve efor kaybına neden olmaktadır. Ayrıca gözleme ile yapılan görsel sınıflandırmada, bitkide bulunan hastalıkların birbirine benzetilmesi sonucu yanlış sonuçların çıkarılma olasılığı çok yüksektir. Hastalıkların özelliklerinin tam bilinmemesinden kaynaklı, hastalık yayılma sürecini kontrol altına alma konusunda da sorunlar yaşanmaktadır. Ayrıca bazı yaprak tabanlı hastalıklar arası teşhisin zor ve ön bilgi gerektirmesi, bu alanda bilgisayar tabanlı yapılan çalışmaların gerçekleştirilmesine olanak vermiştir. Böylece, üretici tarafında ön bilgi gerektirmeyen, daha isabetli sınıflandırma raporu sunabilen bilgisayar tabanlı bir analiz sistemi kullanılarak bitki üzerinde hastalığın teşhisi sağlanacak ve gerekli önlemlerin alınmasına olanak sunacaktır. Böyle bir sistemi sağlamak amacıyla, literatürde derin öğrenme ve görüntü işleme alanında domates yaprakları üzerinde gerçekleştirilmiş birçok araştırma ve çalışma mevcuttur.

Mokhtar vd. [2] tarafından gerçekleştirilen domates yaprağı odaklı hastalık tespiti çalışması incelendiğinde, yaprakların hasta veya sağlıklı olma durumunu belirlemeye yardımcı bir yöntem önerildiği görülmektedir. Modele verilen görüntü öncelikle ön işlemden geçirilir. Ardından "Gri Seviye Belirleme Oluşum Matrisi (GLCM)" sayesinde görüntüden istenilen yapı çıkarılır. Eğitim "Destek Vektör Makinesi (SVM)" kullanılarak yapılır ve K-Fold çapraz doğrulama tekniğiyle değerlendirilir. İşlemler sonucunda %99,83 lük doğruluk değeri elde edilmiştir.

Bir başka makalede [3], öğrenme aktarımı yoluyla derin evrişimli sinir ağlarını (ESA) kullanarak domates yaprağı hastalığını tanımlamaya odaklanılmıştır. Kullanılan ağlar, ResNet'in [4], AlexNet [5], GoogLeNet [6] ve önceden eğitilmiş derin öğrenme modellerine dayanmaktadır. İlk önce stokastik gradyan iniş (SGD) ve Adam

optimizasyon yöntemi [7] kullanılarak bu ağların göreceli performansı karşılaştırılmış ve SGD optimizasyon yöntemiyle ResNet'in en yüksek sonucu olarak, en iyi doğruluk oranı %96,51'e ulaşılmıştır. Daha sonra, ince ayar yapmak için en iyi kombine edilmiş model kullanılmıştır ve en yüksek doğruluk oranı %97,28 olarak elde edilmiştir.

Literatürde bulunan diğer bir benzer çalışmada ise [8], domates bitkisi yaprak görüntüleri, bir sağlıklı ve sekiz hastalık sınıfından oluşan PlantVillage [9] veritabanından alınmıştır. Bu çalışmada, domates bitki yaprağının sağlıklı veya hastalıklı olarak sınıflandırılması ve ayrıca hangi hastalık sınıfına ait olduğu konusunda AlexNet, VGG16 [10], GoogLeNet, MobileNetV2 [11] ve SqueezeNet'in [12] derin öğrenme modelleri kullanılmıştır. VGG16 modeli, AlexNet, GoogLeNet, MobileNetV2 ve SqueezeNet'e kıyasla %99,17 doğruluk sağlayarak daha iyi performans göstermiştir. Veri eğitimi için kullanılan Derin Evrişimli Sinir Ağının (DCNN) eğitimi için çok fazla veri gerekmektedir. Fakat tarımda her zaman istenilen şekilde veri bulunmamaktadır. Bu nedenle, yaprak hastalığı tanımlamasının doğruluğunu geliştirmek için "Variational Auto-Encoder (VAE)" tarafından desteklenen hafif bir domates yaprağı hastalığı tanımlama ağı önerilmiştir [13]. Bu yöntemle hastalık kategorisindeki yaprakların doğru tespit oranı %94,17, sağlıklı yaprakların doğru tespit oranı %98,27 olarak kaydedilmiştir.

Bir başka disiplinler arası gerçekleştirilen çalışmada, yine PlantVillage domates veri kümesi ve domates hastalığı sınıflandırma problemi için en uygun ML/DL modellerinin belirlenmesi amaçlanmıştır [14]. Çalışmada, yerel ikili desen (LBP) ve GLCM yöntemleri kullanılarak 105 renk özelliği çıkarılmıştır. Ayrıca, veri kümesi ve sınıflandırma görevi için test edilen ML/DL algoritmaları arasında ResNet34 [4] ağında %99,7 doğruluk, %99,6 kesinlik, %99,7 duyarlılık ve %99,7 F1 puanı ile en iyi sonuçlar elde edilmiştir.

Bir diğer çalışmada ise, bitki hastalığının belirti ve semptomlarını bitki yapraklarındaki asemptomatik dokulardan ayırt etmek için bir algoritma önermişlerdir [15]. Algoritma, H (HSV renk uzayından) ve a (CIELAB renk alanı) renk kanallarının histogramlarını manipüle etmektedir. Önerilen algoritma, 19 bitki türü, 82 hastalık görüntüleri içeren çok çeşitli verilerde test edilmiştir. Kanal a, geçiş bölgesini semptomun bir parçası olarak görme eğilimindeyken, kanal H'nin onu sağlıklı doku olarak görme eğiliminde olduğu saptanmıştır. Bu sonuç, kanal a'nın geçiş bölgesinin %50'den fazlasını hastalıklı doku olarak sınıflandırdığı gözlemlenmiştir.

Bir başka çalışmada da yazarlar [16], bitki türlerinin tanınması için geleneksel yöntem ve derin öğrenme yaklaşımı olmak üzere iki tür yaklaşım kullanmışlardır. Geleneksel yöntemde öznitelik çıkarımı yapılmıştır. Çıkarılan öznitelikler farklı sınıflandırıcılar kullanılarak sınıflandırılmış ve bitki türlerinin tanınması bağlamında farklı derin öğrenme mimarileri test edilmiştir. Lojistik regresyonlu VGG16 ESA mimarisi, Leaf12 veri kümesi için %97,14 doğrulukla sonuçlanmıştır. Sınıflandırıcı olarak lojistik regresyonlu VGG19[10] mimarisi kullanılarak Folio [17], Flavia [18] ve İsveç yaprak [19] veri kümeleri için %96,53, %96,25 ve %99,41 doğruluk elde edilmiştir.

Daha güncel bir konu olan, derin öğrenme tabanlı gerçekleştirilen çalışmada ise, ESA kullanılarak 14 farklı mahsul türünde 26 hastalığın tanımlanması için yapılan yaklaşım anlatılmıştır [20]. Halka açık ve kontrollü şekilde toplanan 54306 yaprak görüntüsü içeren veri kümesi üzerinde AlexNet ve GoogleNet mimarileri kullanılarak yaprak sınıflandırması yapılmıştır. Modellerin eğitimi sıfırdan veya öğrenme aktarımı olarak belirtilen iki farklı şekilde gerçekleştirilmiştir. Modelin uygulanmasında Caffé eğitim kümesi kullanılarak %99,35 olarak yüksek bir doğruluk oranı elde edilmiştir.

Derin öğrenme yaklaşımının uygulandığı bir başka çalışmada ise, Zaki vd. [21] MobileNetV2 kullanarak yaprak üzerindeki hastalığı tespit etmeye çalışmışlardır. MobileNet model üzerinde, üç tür domates hastalığını tespit etmek için ince ayar (fine-tuning) yapılmıştır. Algoritma, PlantVillage veri kümesinden alınan 4671 görüntü üzerinde test edilmiştir. Sonuçlar, MobileNetV2'nin hastalığı %90'dan fazla doğrulukla tespit edebildiğini göstermiştir.

Hassas tarımda kullanılabilen dronelerin geliştirilerek domates yapraklarında hastalık tespiti yapabilesini hedefleyen çalışmada, dronelar kızılötesi kameralarıyla çektikleri fotoğrafları ZigBee ağı üzerinden iyi, ortalama ya da kötü yaprak olmasına göre görüntünün sınıflandırılacağı sisteme göndermektedirler [22]. Dronelar, yaprak tespitinin ardından yaprak kalitesine göre pestisitlerin yapraklara püskürtülmesi amacıyla kullanılmıştır. Yöntem, Inception modeliyle geliştirilmiştir ve toplamda kaç veriyle işlem yapıldığı belirtilmemesine rağmen kullanılan veri kümesindeki fotoğrafların sayısının artmasıyla doğruluk oranının %99'a kadar çıktığı raporlanmıştır.

Literatürde yaprak türü sınıflandırma, yaprak hastalık teşhisi üzerine yapılan çalışmalar dışında, bahsedilen probleme uyarlanabilecek farklı tekniklerin araştırılması için farklı konularda güncel uygulanmış teknikler de araştırılmıştır. Şafak vd. tarafından yaprak sınıflandırma ve hastalık teşhisinde de uygulanabilecek mobil cihazlar üzerinden sürücü yorgunluk durumunun tespiti için 14 katmandan oluşan bir ESA modeli önerilmiştir [23]. Çalışmada önerilen model ile AlexNet, VGG16, ResNet50 ve MobileNet mimarileri karşılaştırılmıştır. Önerilen model %95,65 değerinde doğruluk oranı ile karşılaştırılan mimarilere göre daha yüksek sonuçlar vermiştir. Bir başka çalışmada ise, insan kulak görüntüleriyle cinsiyet tanımak için melez derin öğrenme yöntemi geliştirilmiştir [24]. Karasulu vd. çalışmalarında tekrarlayan sinir ağı (TSA) tipli bileşenlerin ve ESA mimarilerinin bir arada kullanıldığı melez yapılı derin sinir ağı mimarisi önermişlerdir. Alınan sonuçlarda, melez modellerle yapılan cinsiyet tanıma çalışmasında WPUT veri kümesi üzerinde test doğruluğu %87,61 oranında, EarVN veri kümesi üzerinde yapılan çalışmada test doğruluğu ise %85,16 olarak bulunmuştur. Derin öğrenme ağlarının başarısını inceleyen bir diğer çalışmada, imalat makinesi üzerinde gerçek zamanlı toz yatağı görüntülerinin bulunduğu bölgenin izlenmesi ve buna ek olarak kusurların tespit edilebilmesi için derin öğrenme yöntemli bir yaklaşım önerilmiştir [25]. Çalışmada VGG16, InceptionV3 ve DenseNet modelleriyle öğrenme aktarımı uygulanmıştır. Oluşturulan veri kümesini VGG16 modeli %88,3 en yüksek doğruluk oranı ile sınıflandırmıştır.

Önerilen bu çalışmada, farklı derin öğrenme modelleri kullanılarak, domates yapraklarında bulunan en yaygın 9 farklı hastalığın ve sağlıklı olanlarının yüksek doğruluk oranıyla yapay zekâ tabanlı bilgisayar destekli tespit edilmesi amaçlanmıştır. Modeller; sağlıklı domates yaprakları, bakteriyel leke, erken yanıklık, geç yanıklık, yaprak küfü, mozaik virüs, örümcek akarı, sarı yaprak kıvrıkcılığı, septorya yaprak lekesi ve yaprak beneği adlı hastalıklara sahip

yapraklar kullanılarak eğitilmiş ve performansları ölçülmüştür. Kullanılan derin öğrenme modellerinde, öğrenme aktarımı kapsamında başarımların analizi için üç adet önceden eğitilmiş (pre-trained) ağlar (AlexNet, VGG16 ve MobileNetV2) kullanılmış, ayrıca sıfırdan eğitim anlamında ise "T-LeafNet" ismi verilen özel bir model tasarlanmış ve test edilmiştir. Her iki yaklaşımda da veri artırımı tekniklerinin ve derin öğrenme modellerinin eğitim aşamasında uygulanan öğrenme katsayı analizlerinin performanslara etkisi de çalışma kapsamında incelenmiştir.

Çalışmanın 2. bölümünde, kullanılan veri kümesi ve yöntemler hakkında bilgi verilecektir. 3. bölümde deneysel sonuçlarla ilgili somut bilgiler olacaktır. Tasarlanan ESA modeli ve öğrenme aktarımı tabanlı sınıflandırma sonuçları ayrı ayrı açıklanarak karşılaştırma ve tartışmalara yer verilecektir. Makalenin son kısmı olan 4. bölümde ise derin öğrenme kapsamında farklı modellerle gerçekleştirilmiş çalışmanın ortaya çıkardığı nicel sonuçlara ve literatüre olan katkılarına değinilecektir.


2. Materyal ve Yöntem (Material and Method)

2.1. Veri Kümesi (Dataset)

Sunulan çalışmada halka açık veriler sunan Kaggle internet sitesi üzerinden paylaşılan "Tomato Leaf Disease Detection" isimli veri kümesi kullanılmıştır. Bu veri kümesinde 9 farklı domates yaprağı hastalık görüntü verisi bulunmaktadır. Yapılan çalışmada veri kümesindeki tüm hastalıkların tespitinin yapılmasına odaklanılmıştır. Bunlar bakteriyel leke, erken yanıklık, geç yanıklık, yaprak küfü, mozaik virüs, örümcek akarı, sarı yaprak kıvrıkcılığı, septorya yaprak lekesi ve yaprak beneği hastalıklarıdır. Ayrıca bu dokuz hastalığın tespiti için hastalık gözlemlenmeyen (sağlıklı) yaprak görüntü veri kümesi de çalışma ana veri kümesine dahil edilmiştir. Çalışma her veri kümesinde 1000'er adet veri kullanılarak 10 farklı sınıf üzerinden toplamda 10000 adet görüntü verisiyle gerçekleştirilmiştir. Görüntüler JPG formatında ve RGB renk uzayında düzenlenmiştir. Veriler orijinal formatta, herhangi bir ön işlem uygulanmadan çalışmaya dahil edilmiştir. Çalışmada kullanılan veri kümesinden alınan, her sınıfa ait 2'şer adet örnek resim Şekil 1'de gösterilmiştir.

2.2. Yöntem (Method)

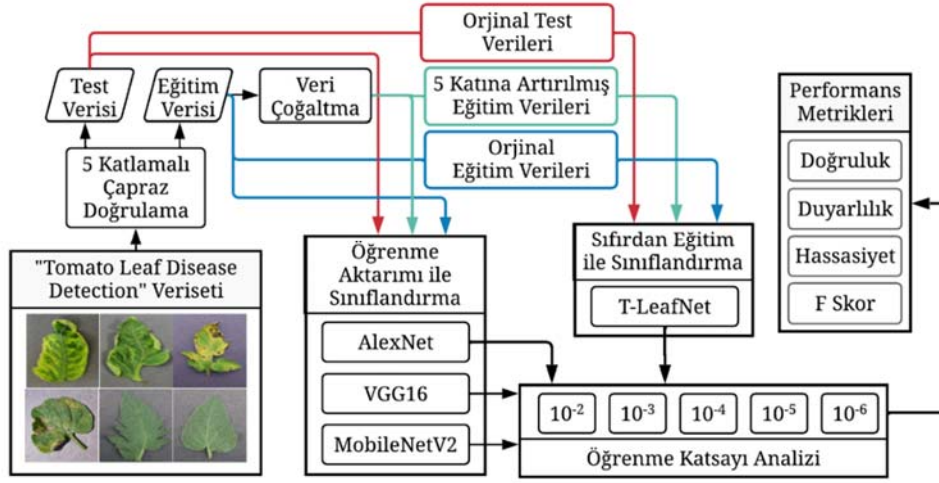
Çalışmada temel olarak derin öğrenme tabanlı sınıflandırma problemlerinde kullanılan öğrenmenin aktarımı ve ESA modellerinin sıfırdan eğitilmesi yaklaşımlarının, domates yapraklarında görülen hastalıkların teşhisindeki uygulanabilirliği incelenmiştir. Bu anlamda domates yapraklarında en yaygın görülen dokuz hastalığın ve sağlıklı yaprakların tespitinde kullanılması üzerine yaklaşımların performans kıyaslaması gerçekleştirilmiştir. Genel çalışmanın akış diyagramı Şekil 2'de gösterilmiştir. Çalışma çapraz doğrulama, veri çoğaltma, öğrenmenin aktarımı temelli derin öğrenme ağlarının kullanımı, özel ESA modeli oluşturulması ve farklı öğrenme katsayıları ile performansların kıyaslanması anlamında beş aşamayı içermektedir.



Şekil 1. Veri Kümesinden Örnek Görüntüler (Example Images from the Dataset)

Çapraz doğrulama, makine öğrenme modellerinin gerçek test verileri kullanılarak elde edilecek sonuçlarının tahmin edilmesi için kullanılan istatistiksel bir doğrulama tekniğidir. Bu yöntemde veri kümesi k adet alt kümeye (fold) bölünmüştür. Yöntemde veri kümesi hem eğitim hem de test kümesi olarak ikiye ayrılmaktadır. Eğitim kümesi üzerinde analizler sonucu model oluşturulur ve test kümesinde model sınanır. Yapılan işlemlerde bir alt küme test için ve k-1 adet alt küme ise eğitim için kullanılmaktadır. İşlemler her k-kat test kümesinde çalışana kadar tekrar etmektedir. İşlemler sonucunda, elde edilen sonuçların ortalaması alınır. Çapraz doğrulama tekniği, veri kümesinde bulunan tüm görüntü verilerinin eğitim veya test kümesinde tam olarak bir kez kullanılmasını sağlamaktadır. Bu çalışmada benzer pek çok çalışmada olduğu gibi modeller üzerinde çapraz doğrulama tekniği 5-katlamalı olarak uygulanmıştır [26]. Veri kümesindeki örnekler sınıflarına göre %80 eğitim ve %20 test olmak üzere ikiye bölünmüştür, sınıflama model başarımları 5 defa farklı eğitim kümeleri ile tekrar edilerek ortalaması performans metriği olarak sunulmuştur. Evrimsel Sinir Ağları (ESA) gürültü ve bozucu etkilere karşı klasik makine öğrenmesi yaklaşımlarından daha gürbüz çalışmakta ve benzer görseller üzerinde daha yüksek başarılı sonuçlar vermektedir. İçlerinde milyonlarca farklı işlevi olan parametre içerirler. Veri kümelerindeki verilerin sayısı arttıkça model parametrelerin optimum seviyeye erişmesi daha efektif gerçekleşir. Modellerde, verinin yetersiz olma probleminde veri artırma (data augmentation) işlemi ile çözümler aranır. Veri artırma sürecinde, sadece eğitim veri kümelerinde bulunan görüntüler üzerinde uzamsal anlamda işlemler uygulanarak ana resme benzer ama ufak

farklılıkların bulunduğu görüntüler oluşturulur. Böylelikle modellerin eğitimi için kullanılacak görüntülerin çeşitlenmesi ve artırımı işlemi gerçekleştirilir. Bu sayede artırılmış eğitim görüntüleri ile daha iyi derin öğrenme modelleri oluşturulabilir [27]. Sunulan çalışmada da test kümelerinde herhangi bir değişiklik yapılmadan eğitim kümelerine artırma işlemi uygulanmıştır. Soldan sağa ve yukarıdan aşağıya çevrilme, farklı açılarda döndürme gibi birçok işlemden geçirilen görüntüler ile model eğitilir. Veri kümesindeki verilere ek olarak eğitim için uygulanan bu teknikler ile farklı hale getirilmiş görüntüler elde edilmiştir. Orijinal görüntüler üzerinde uzamsal anlamda uygulanan tekniklere göre elde edilen görüntülere ait birkaç örnek Şekil 3'te gösterilmiştir. Çalışmada veri artırma yaklaşımının sınıflandırma performansına etkisini incelemek ve kıyaslama yapabilmek amacıyla orijinal veri kümesi dışında, 5 katına artırılmış veri kümesi modellere ayrı verilerek üzere oluşturulmuş ve kaydedilmiştir. Böylece uygulanacak derin öğrenme modelleri için aynı veri kümesinin eğitim ve test performanslarının ölçülmesi sağlanmıştır. ESA modelleri sınıflandırma yapabilmek amacıyla kullanıcının istediği yönde farklı özellikleri öğrenerek eğitilebilen, birden çok katmanlı olarak yapılandırılan sinir ağlarıdır. Katmanı az olan geleneksel yapay sinir ağı mimarilerine kıyasen daha yüksek başarı sağlayan, özellik çıkarma yeteneğine sahiptirler. Geleneksel yöntemlere oranla az ön işleme ihtiyaç duyarlar. Verilerin uygunluğuna göre çoğu zaman sınıflandırma işlemi için hiçbir ön işlem gerektirmezler [28]. ESA mimarilerinin sınıflandırma problemlerinde iki farklı kullanımı mümkündür. Öğrenmenin aktarımı olarak tanımlanan kullanımlarda, büyük veriler ile önceden



Şekil 2. Akış Diyagramı (Flow Chart)

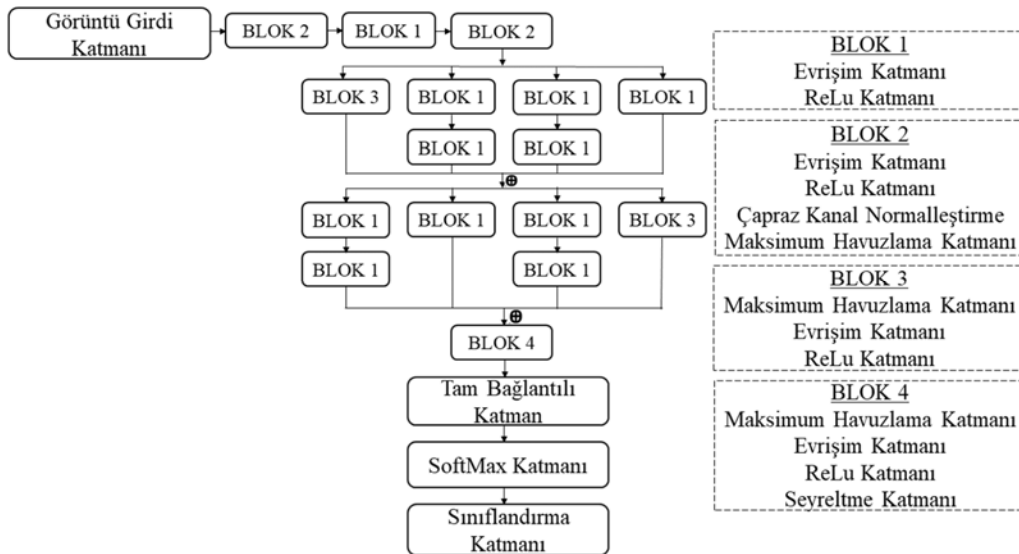


Şekil 3. Veri Çoğaltma Teknikleri ile Üretilen Görüntü Örnekleri (The Augmented Images Generated by Data Augmentation Techniques)

eğitilmiş ve yüksek sınıflandırma başarımı elde edilmiş ağların farklı problemlerde kullanılması amaçlanır. Bu kullanımda, mevcut eğitilmiş ağların ağırlıkları başka bir problemin sınıflandırılmasında ön bilgi olarak kullanılır. Ağların eğitim süreleri, aynı ağların sıfırdan eğitime durumlarına göre çok daha kısadır. Ancak uygulanacak yeni problemin mevcut ağlara uygunluğu performans için önemli bir kriterdir. Diğer bir kullanım olan ağların sıfırdan eğitilmesinde ise sınıflandırma performansı, veri kümesinin boyutu ile doğrudan ilişkilidir. Bu çalışmada, bahsedilen iki kullanım şekli olan öğrenmenin aktarımı ve sıfırdan eğitim yaklaşımları domates yaprakları üzerinde hastalık tipi ve sağlıklı yaprak sınıflandırması problemi kapsamında incelenecektir. Öğrenmenin aktarımı için literatürde başka sınıflandırma problemlerinde sıkça kullanılan AlexNet, VGG16 ve MobileNetV2 derin öğrenme mimarileri, sunulan çalışmada domates yapraklarının sınıflandırılması kapsamında incelenmiştir. Wang vd., AlexNet tabanlı bir öğrenme aktarımı yöntemi önermiş ve alkolizm tanımlama probleminde önerdikleri ağın performansını diğer ESA mimarileri ile kıyaslayarak değerlendirmişlerdir [29]. Kıyaslama neticesinde en yüksek sınıflandırma başarımını AlexNet ile elde ettiği raporlanmıştır. Bir başka çalışmada ise, Wu vd. [30] çiçeklerin renk ve doku özelliklerine göre doğru şekilde sınıflandırılabilmesi için VGG16 mimarisini öğrenme aktarımı kapsamında kullanarak etkili bir çiçek sınıflandırma yaklaşımı önermişlerdir. Öğrenmenin aktarımı dahilinde analiz edilen son ağ MobileNetV2 olarak belirlenmiştir. Bu ağın seçiminde mobil tabanlı sistemlere adaptasyonunun kolay olması en önemli kistas olmuştur. MobileNetV2 tabanlı sınıflandırma çalışmaları incelendiğinde ise performansının yüksek ve eğitim sürelerinin VGG16 ve AlexNet gibi daha karmaşık yapılardan kısa olduğu gözlemlenmiştir. Yapılan mobil ağa ve geleneksel yöntemlerle performans karşılaştırmasına dayalı tam otomatik hibrit insan spermli algılama ve sınıflandırma sistemi çalışmasında [31], yapılan derin öğrenme testlerinde MobileNet, her bir kat için diğer modellere göre daha az eğitim süresi ve kaynak tüketimi ile %87 doğruluk oranı sağlamıştır. Çalışma kapsamında kullanılan ağlardan AlexNet, 60 milyon parametre ve 650.000 nörona sahip derin evrişimli bir sinir ağıdır [5]. AlexNet mimarisi beş evrişimli katmandan oluşur. Bu katmanlardan bazılarını maksimum havuz katmanları izlemektedir. Üç adet tam bağlı katmanı vardır. Mimariye verilen çıktıda softmax özelliğini etkinleştirebilmek için bir astar katmanı vardır. Katmanlarından tam bağlı olanlarda aşırı uyum düzeyini azaltmak için dropout katmanlar arası düzenleme yöntemi kullanılmaktadır. AlexNet mimarisinde ReLu aktivasyon işlevi ilk yedi katmanın her birine

uygulanmaktadır [32]. Veri girdi boyutları, AlexNet'in girdi piksel boyutuna uygun olacak şekilde düzenlenmelidir. Öğrenmenin aktarımı kapsamında uygulanan diğer bir ağ olan VGG16, A. Zisserman ve K. Simonyan tarafından önerilen evrişimli bir sinir ağı modelidir. Önerilen model 13 konvolüsyon ve 3 tam bağlı katmandan oluşmaktadır ve toplamda 14 milyondan fazla görüntü verisi içeren ve 1000 sınıfı olan ImageNet'te [33] %92,7'lik doğruluğa ulaşmaktadır [10]. VGG16 ILSVRC-2014'te sunulan en ünlü modellerden biri olma özelliği taşımaktadır. Sahip olduğu büyük çekirdek boyutlu filtreleri, birden fazla 3x3 çekirdek boyutuna sahip filtrelerle değiştirme özelliğiyle AlexNet mimarisine göre daha fazla iyileştirme yapmaktadır. Öğrenme aktarımı anlamında uygulanan bir başka ağ olan MobileNet ise hesaplama kaynaklarının sınırlı olduğu mobil platform odaklı bir derin öğrenme ağ mimarisidir [34]. VGG16'dan 32 kat daha küçük olmasına rağmen yine de benzer doğruluğa sahiptir. Ağ ne kadar küçükse o kadar hızlı çalışmaktadır ve daha az sistem kaynaklarını kullanır. Evrişim katmanlarının sıkıştırılması, ağırlıkların sınıflandırılması ve en küçük ağırlıkların atılmasıyla meydana gelmiştir. Ayrıca, MobileNet tasarımında benzer sinir ağlarına kıyasla 9 kat daha hızlı hale getiren derinlemesine ayrılabilir konvolüsyonlar kullanılmaktadır. Mobil ağ, bu türde 17 bloğa (derinlik açısından ve noktasal evrişimi ayrı katmanlar olarak sayılırsa 28 katman) ve onu izleyen küresel ortalama havuzlamaya ve bir sınıflandırma katmanına sahiptir [35]. MobileNetV2 olarak adlandırılan geliştirilmiş bir sürüm daha sonra Google tarafından orijinal sürümde küçük değişikliklerle tanıtılmıştır [11].

Öğrenme aktarımı dışında 46 katmanlı bir ESA modeli T-LeafNet tasarlanmış ve sıfırdan eğitilerek bu yaklaşım da domates yapraklarının sınıflandırılması konusunda analiz edilmiştir. T-LeafNet 224x224 görüntü boyutunda bir girdi katmanı içermektedir. Bloklar birbirine bağlanırken bazı katmanlarda paralel şekilde uygulanmıştır. İki farklı paralel uygulama sonrasında çıkan sonuçlar, birleştirme vektörü kullanılarak birleştirilmiştir. Bu model üzerinde çapraz kanal normalleştirme katmanı kullanılmıştır. Tam bağlı katmandan önce özellik vektörünün boyutunu azaltmak için Blok 4'te tanımlanan bir seyreltme katmanı dahil edilmiştir. Model üzerinde, ilk evrişim katmanındaki filtreler 11x11 olarak sabitlenmiştir. Daha sonra kademeli olarak azaltılmıştır. Son katmanda 1x1 filtreler uygulanmıştır. Her evrişim katmanında kullanılan toplam filtre sayısı 96'dan 128'e yükseltilecek işlemler yapılmıştır. Maksimum havuzlama katmanında 2x2 dolgu 3x3 pencere boyutu kullanılmıştır. Tasarlanan T-LeafNet modeli Şekil 4'te sunulmuştur.



Şekil 4. Tasarlanan ESA Modeli T-LeafNet (Designed CNN Model T-LeafNet)

Tasarlanan T-LeafNet modelinde; kullanılan her blok için eklenen evrişim katmanı, girdi verisini bir evrişim sürecinden geçirerek çıktıya dönüştüren önemli bir bileşendir. Bu süreç içerisindeki düzlem sayısı S olarak belirlenir. Bu katmandaki hacim her düzlem yapısının sınırlı bir boyut içeren filtreden oluşan M sayıda düzlem içerir. W_{ni} olarak belirtilen ağırlık matrisindeki parametreler, i . düzlem üzerinde olan bitişik yapıli filtrelerden oluşmaktadır. Filtre, n . boyuttaki giriş düzlemi üzerinde kaydırıldığında, ağırlık matrisi ile A_n değer matrisinin işleme alınmasıyla, iki boyutlu olan $W_{ni} * A_n$ matrisi elde edilir. Tüm girdi düzlemi matrisleri, bir B_i matrisi yardımıyla toplanarak polarlanır. Bu bileşenin matematiksel formülü Eş. 1'de verilmiştir. Y_i özellik haritası şeklinde açıklanır.

$$Y_i = f\left(B_i + \sum_{n=1}^S W_{ni} * A_j\right) \quad i = 1,2,3, \dots, M \text{ olduğunda} \quad (1)$$

ESA modellerinde kullanılan aktivasyon fonksiyonu "Doğrultulmuş Lineer Birim (ReLU)" olarak tanımlanmaktadır ve bu fonksiyon ESA'nın öğrenme hızına ek olarak sınıflandırma doğruluğunu artıran özellik haritasına uygulanmaktadır. Bu fonksiyonun çalışma şekli Eş. 2'de gösterilmiştir.

$$f(\alpha) = \max(0, \alpha) \quad (2)$$

Maksimum havuzlama işlemi, girdi evrişim katmanından çıktıktan sonra gerçekleştirilmektedir. Evrişim aşında kullanılan özellik haritalarının oluşturduğu blokların maksimum değerini hesaplamaktadır. Bu katmandan sonra öğrenilen özellikler tam bağlı katmana gönderilir. Tam bağlı katmandaki nöronlardaki işlemler Eş. 3'te verilmiştir. Denkleme nöronların ağırlığı ω_j 'dir. Giriş özellikleri α_j olarak gösterilmiştir ve bias değeri b ile gösterilirken, n değeri de görüntü üzerindeki toplam özellik sayısıdır.

$$O = f\left(b + \sum_j^n \omega_j \alpha_j\right) \quad (3)$$

Softmax işlevi, ağırlık son katmanı olan çıktı katmanında etkinleştirme işlevi olarak çalışır ve Eş. 4'te gösterilmiştir. K değeri işlem yapılan sınıf sayısıdır ve bu çalışmada 10 olarak kullanılmıştır.

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (4)$$

Derin öğrenme kapsamında test edilen AlexNet, VGG16, MobileNetV2 ve geliştirilen T-LeafNet modeli farklı öğrenme katsayısı parametreleri ile eğitilmiş ve performanslar kıyaslanmıştır. Sınıflandırma performansları karışıklık matrisi metrikleri üzerinden ölçülmüştür. Karışıklık matrisi, model performans değerlendirmesi yapılırken, gerçek gözlemlere karşı doğru ve yanlış tahminleri listeler. Birçok yararlı performans ölçütü, karışıklık matrisindeki değerlerden çıkarılır [36]. Karışıklık matrisi üzerinde yer alan Gerçek Pozitifler (TP), modelin ilgili sınıf için doğru sınıflandırdığı resim sayısını belirtir. Gerçek Negatifler (TN) ise modelin ilgili sınıfa ait olmayan resimler için verdiği doğru kararı gösterir. Yanlış Negatif (FN) ve Yanlış Pozitif (FP) değerleri ise resimlerin ilgili sınıfta olmasına rağmen sınıf dışında veya ilgili sınıfta olmadığı halde sınıf içerisinde değerlendirdiği imge sayısını gösterir. Bu değerler kullanılarak 4 farklı performans metriği modellerin kıyaslanmasında kullanılmıştır. Metriklerin matematiksel formülleri denklem Eş. 5, Eş. 6, Eş. 7 ve Eş. 8'de verilmiştir.

$$\text{Doğruluk Oranı} = (TP + TN) \div (TP + TN + FP + FN) \quad (5)$$

$$\text{Hassasiyet} = TP \div (TP + FP) \quad (6)$$

$$\text{Duyarlılık} = TP \div (TP + FN) \quad (7)$$

$$F1 \text{ Skor} = 2 \times (\text{Hassasiyet} \times \text{Duyarlılık}) \div (\text{Hassasiyet} + \text{Duyarlılık}) \quad (8)$$

Doğruluk oranı, doğru şekilde sınıflandırılmış örneklerin kullanılan tüm veri kümesine oranıdır. Hassasiyet ise elde edilen modelin tahmini olarak oluşturulan pozitif örneklere göre ne kadar kesin olduğunu ve tahmin edilen pozitif verilerin ne oranda gerçek pozitif olduğunu gösterir. Hassasiyet, FP için yapılan tahminlerin maliyetlerinin hangi dilimde yüksek seviyede olduğunu bulabilmek için gerekli ve önemli bir parametredir. Duyarlılık, TP örneklerin ne oranda yakalandığının model tarafından pozitif olarak etiketlenerek ölçülmesidir. Elde edilen FN örnekleriyle çıkarılan yüksek maliyetlerde kullanılan önemli bir parametredir. F1 skor metriği ise hassasiyetin ve gerçek pozitif değerlerin oranının (duyarlılık) harmonik ortalamasıdır. Sınıflandırıcının performansının ne düzeyde olduğunu bir ölçüsüdür ve sınıflandırıcıları karşılaştırmak için sıklıkla kullanılmaktadır.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

Çalışmada "Tomato Leaf Disease Detection" isimli veri kümesi üzerinde derin öğrenme tabanlı dört farklı sınıflandırma modeli, öğrenme aktarımı ve sıfırdan eğitim yaklaşımları çerçevesinde uygulanmıştır. 10 sınıf yapısında oluşturulmuş veri kümesi üzerinde yöntemler test edilmiştir. Veri kümesi içerisinde sağlıklı yaprak görüntüleri, herhangi bir deformasyon gözlemlenmeyen domates yapraklarını içermektedir. Hastalıklı yaprak görüntüleri için sınıf belirlenmesinde en sık görülen ve tarımda en yüksek maliyet kaybına sebep olan dokuz hastalığa ait domates yapraklarının görüntüleri çalışmaya dahil edilmiştir. Toplam 10000 görüntü, 5-katlamalı çapraz doğrulama tekniği ile her kat (fold) 8000 görüntü eğitim, 2000 görüntü test için ayrılmış, model performansları 5 katlama sonunda ortalama başarımları metrikleri ile ifade edilmiştir.

Çalışmada kullanılan veri kümesindeki örnek sayısı, çevirme, döndürme gibi uzamsal anlamda farklılığa neden olan yöntemler kullanılarak ve piksel değeri bazlı parlaklık, ton ve kontrast özelliklerinde değişiklikler yapılarak artırılmıştır. Oluşturulan metodolojide domates bitkisinin yapraklarında oluşan 9 farklı hastalığı tespit edebilen T-LeafNet isimli bir ESA modeli önerilmiştir. Çalışmada kullanılan ESA modelleri, orijinal veri kümesi ve artırılmış versiyonu ile 20 epoch süresinde eğitilmişlerdir. Farklı öğrenme oranları ile sınıflandırmada elde edilen doğruluk oranları ölçülmüştür. Modellerin eğitiminde kritik öneme sahip olan öğrenme katsayısı (learning rate) 10^{-2} , 10^{-3} , 10^{-4} , 10^{-5} ve 10^{-6} değerleri ile ayrı ayrı analiz edilerek sonuçlar raporlanmıştır. Öğrenme oranlarının değişimine göre uygulanan ESA modellerinde elde edilen doğruluk oranları (accuracy) Tablo 1'de sunulmuştur. Ayrıca, orijinal ve artırılmış veriler üzerinden, farklı öğrenme oranlarının uygulanmasıyla elde edilen doğruluk oranları da aynı tabloda gösterilmiştir. T-LeafNet modeli için orijinal veri kümesine sırasıyla 10^{-2} , 10^{-3} , 10^{-4} , 10^{-5} ve 10^{-6} öğrenme oranları verilerek %94,96, %94,36, %89,35, %79,64 ve %54,38 değerli doğruluk oranları elde edilmiştir. Artırılmış veri kümesinde ise aynı parametrelerde sırasıyla %97,32, %96,59, %93,02, %84,45 ve %58,84'lük sınıflandırma doğruluk başarımları elde edilmiştir. Orijinal ve artırılmış veri kümelerinin ikisinde de en iyi sonucun 10^{-2} öğrenme katsayısı ile elde edildiği görülmektedir. Oluşturulan T-LeafNet ESA mimarisinde en yüksek doğruluk oranı artırılmış veri kümesi üzerinde 10^{-2} öğrenme katsayısı ile %97,32 ölçülmüştür.

Öğrenme aktarımı kapsamında AlexNet, VGG16 ve MobileNetV2 mimarileri seçilerek bu mimariler üzerinden domates yapraklarının sınıflandırma başarımları elde edilmiştir. AlexNet mimarisinde, orijinal veri kümesi üzerinden sırasıyla 10^{-2} , 10^{-3} , 10^{-4} , 10^{-5} ve 10^{-6} öğrenme oranıyla %0, %96,94, %97,24, %94,36 ve %86,04 doğruluk

Tablo 1. Domates Yaprak Sınıflandırma Sonuçları (Ö.K.: Öğrenme Katsayısı)
(Tomato Leaf Classification Results (Ö.K.: Learning Coefficient))

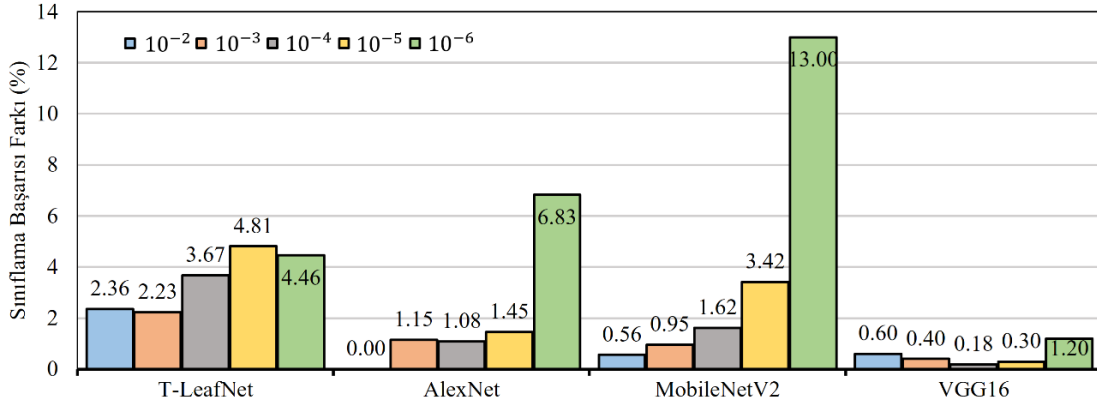
Orijinal Veri Kümesi		Artırılmış Veri Kümesi						
Ö. K.	T-LeafNet	AlexNet	MobileNet V2	VGG16	T-LeafNet	AlexNet	MobileNet V2	VGG16
10 ⁻²	94,96	0	97,68	97,8	97,32	0	98,24	98,4
10 ⁻³	94,36	96,94	98,15	98,5	96,59	98,09	99,1	98,9
10 ⁻⁴	89,35	97,24	96,85	99,03	93,02	98,32	98,47	99,21
10 ⁻⁵	79,64	94,36	93,27	98,5	84,45	95,81	96,69	98,8
10 ⁻⁶	54,38	86,04	74,52	97,2	58,84	92,87	87,52	98,4

oranları elde edilmiştir. Artırılmış veri kümesi üzerinden yapılan eğitim işlemleri sonucunda ise aynı sıradaki öğrenme oranlarıyla %0, %98,09, %98,32, %95,81 ve %92,87'lik doğruluk oranları elde edilmiştir. AlexNet mimarisinin öğrenme katsayı parametrelerinde daha minimal artışlar sunan değerlerde sınıflandırma yapabildiği gözlemlenmiş, 10⁻² değerinde herhangi bir sınıflandırma gerçekleştirememiştir. En yüksek başarımlar %98,32 doğruluk oranı ile artırılmış veri kümesi üzerinde 10⁻⁴ öğrenme katsayısı kullanılarak elde edilmiştir. VGG16 mimarisinde de AlexNet mimarisinde yapılan işlemler tekrar edilmiştir. Orijinal veri kümesinde sırasıyla 10⁻², 10⁻³, 10⁻⁴, 10⁻⁵ ve 10⁻⁶ öğrenme oranlarıyla %97,8, %98,5, %99,03, %98,5 ve %97,2 doğruluk oranı sonuçları bulunmuştur. Artırılma işleminden sonra ise aynı öğrenme oranlarıyla sırasıyla %98,4, %98,9, %99,21, %98,8 ve %98,4'lük doğruluk oranları elde edilmiştir. VGG16 için en yüksek sınıflandırma performansı %99,21 doğruluk ile 10⁻⁴ öğrenme katsayısı ve artırılmış veri kümesi eğitimi kullanılarak elde edilmiştir. MobileNetV2 mimarisi kullanılarak orijinal veri kümesinde her bir öğrenme katsayısına göre %97,68, %98,15, %96,85, %93,27 ve %74,52 doğruluk sonuçları elde edilmiştir. Artırılmış veri kümesinde ise sırasıyla %98,24, %99,1, %98,47, %96,69 ve %87,52 sınıflandırma performansları ölçülmüştür. Artırılmış veri kümesindeki doğruluk oranları tüm mimarilerde daha yüksek olarak bulunmuştur. AlexNet ve VGG16 mimarilerinde 10⁻⁴ ve MobileNetV2'de de 10⁻³ öğrenme oranlarıyla en yüksek doğruluk sonuçları elde edilmiştir.

Artırılmış veri kümesi üzerinde 10⁻⁴ öğrenme katsayılı VGG16 ağı, %99,21 doğruluk oranı ile sınıflandırmayı gerçekleştirmiştir. Orijinal veri kümesi üzerinde de en yüksek sınıflandırma başarımları, 10⁻⁴ öğrenme katsayılı VGG16 ağı ile %99,03 sonucu bulunarak elde edilmiştir. Tablo 1'de öğrenme katsayısının T-LeafNet modelinin başarımlarının değişmesinde büyük etken olduğu görülmektedir. Orijinal ve artırılmış veri kümesinde T-LeafNet 10⁻² öğrenme katsayısı ile en yüksek değerleri alırken 10⁻⁶ öğrenme katsayısıyla başarımlarının %90'lardan %50'li sonuçlara kadar düştüğü görülmektedir. T-LeafNet ağının az katmanlı bir yapıda olması öğrenme katsayısının daha yüksek seviyelerinde daha fazla ağırlık değeri güncellemesi yapılabilmesi nedeniyle daha etkili olmasını sağlamıştır. VGG16 gibi daha karmaşık ve büyük yapıda ağlarda, daha düşük öğrenme katsayıları ise daha yüksek oranda sonuç vermektedir. Çünkü karmaşık ağlar daha hassas değişimlere ihtiyaç duymaktadırlar ve bu hassas değişimlere göre sonuçlar daha etkili değişebilmektedir. VGG16 ağı da bu olgu üzerinden incelendiğinde farklı öğrenme katsayıları arasında T-LeafNet ağına göre daha az miktarda fark oluştuğu görülmektedir. MobileNetV2 ile eğitilen veri kümesinde ise başarımların 10⁻⁶ öğrenme katsayısı değerinde düşüş göstermiştir. MobileNetV2 ile elde edilen en yüksek doğruluk oranı %99,1 ile artırılmış veri kümesinde elde edilmiştir. AlexNet mimarisi ise çalışma için kullanılan veri kümesi üzerinde 10⁻² öğrenme katsayısı ile hem orijinal hem de artırılmış veri kümesinde başarısız olmuştur. 10⁻² öğrenme katsayısı kullanılırken eğitim aşamasında ağırlıklarda büyük bir değişim yapıldığı için modeller öğrenmeyi sağlayamamış ve bu nedenle %0 başarı elde edilmiştir. 10⁻² değerine göre daha

hassas öğrenme katsayılı ağırlıkların kullanılması sonuçların daha doğru bir şekilde elde edilmesini sağlamıştır. Yapılan çalışmada öğrenmenin aktarımı kapsamındaki ESA mimarileri kullanılırken 10⁻⁵ ve 10⁻⁶ öğrenme katsayılarının kullanılması nedeni veri eğitiminde minimal öğrenme katsayıları kullanılarak en yüksek doğruluk oranlarına ulaşmanın hedeflenmiş olmasıdır.

Sıfırdan eğitilen özel tasarlanan ESA modeli (T-LeafNet) ve öğrenmenin aktarımı kapsamında test edilen VGG16, MobileNetV2 ve AlexNet mimarilerinde orijinal veri kümesine göre, artırılmış veri kümelerinde daha yüksek sınıflandırma doğruluğu gözlemlenmiştir. Diğer çalışmalarda raporlandığı gibi, mevcut çalışmada da veri artırma tekniklerinin bütün ESA modellerinde sınıflandırma başarımlarını artırmıştır. Şekil 5'te veri artırmanın kullanılan veri kümesinin sınıflandırılmasında ağ ve öğrenme katsayı bazlı etkisi verilmektedir. Grafikte 10⁻², 10⁻³, 10⁻⁴, 10⁻⁵ ve 10⁻⁶ öğrenme katsayılarının kullanımı farklı renklerle belirtilmiştir. Kullanılan veri kümesine göre, artırılmış veri kümesinde yüzdesel olarak daha yüksek sınıflama başarımları elde edildiği gösterilmektedir. Veri artırma yönteminin, sınıflandırma başarımlarını yükseltmeye yarayan bir yöntem olduğu grafik üzerinden kıyaslamalı görülebilir. Şekilde de görüldüğü üzere, veri artırımının en büyük etkisi %13'lük bir artışla MobileNetV2 ağının 10⁻⁶ öğrenme katsayısı üzerinde ölçülmüştür. Aynı öğrenme katsayısı ile AlexNet mimarisi üzerinde %6,83, T-LeafNet üzerinde %4,46 ve VGG16 üzerinde %1,2 değerinde başarımların artışı elde edilmiştir. 10⁻⁵ öğrenme katsayısı ile veri artırımı sağlanarak en yüksek sınıflandırma doğruluğu T-LeafNet'te %4,81 olarak kaydedilmiştir. MobileNetV2 üzerinde %3,42, AlexNet üzerinde %1,45 ve en az olarak VGG16 mimarisinde %0,3 değerli artış olmuştur. Öğrenme katsayısı 10⁻⁴ olarak mimarilere verildiğinde T-LeafNet üzerinde %3,67, MobileNetV2'de %1,62, AlexNet üzerinde %1,08 ve VGG16'da %0,18'lik bir artış olmuştur. 10⁻³ öğrenme katsayısı ile en yüksekten en düşük başarımların artırımına göre sırasıyla T-LeafNet %2,23, AlexNet %1,15, MobileNetV2 %0,95 ve VGG16 %0,4 değerinde sonuçlar vermişlerdir. Son olarak 10⁻²'lik öğrenme katsayısına bakıldığında ise AlexNet'in veri artırımından hiçbir şekilde olumlu etkilenmediği görülmektedir. %0 değerinde bir sonuç elde edilmiştir. Veri artırımı ile aynı öğrenme katsayısı ile T-LeafNet, MobileNetV2 ve VGG16 üzerinde sırasıyla %2,36, %0,56 ve %0,6 değerinde sınıflandırma doğruluğunun arttığı gözlemlenmiştir. Sonuçlar incelendiğinde veri artırımı yaklaşımının T-LeafNet merkezinde kullanılan her öğrenme katsayısı üzerinde en az %2,36'lık bir başarımların artırımına neden olduğu görülmektedir. Bu durum da T-LeafNet üzerinde yapılan veri artırım işleminin kullanılan farklı öğrenme katsayıları üzerinde verimli bir sonuç verdiğini göstermektedir. T-LeafNet üzerinde %2,23 ile %4,81 arasında bir değişim söz konusudur. T-LeafNet mimarisinin küçük yapıda oluşu ve karmaşık olmayışı elde edilen yüksek değişimi sağlamıştır. Veri artırımının en az etkisi ise VGG16 mimarisinde elde edilmiştir. Başarımlar değerlerindeki artış %0,18 ile %1,2 arasında minimal etkilerle gözlemlenmiştir. VGG16 ağ yapısı daha büyük ve daha karmaşık olduğu için yapılan veri artırımının etkisi diğer mimarilere göre daha az olmuştur. Elde edilen sonuçlar, geliştirilen modelin



Şekil 5. Veri Artırmanın Veri Kümesinin Sınıflandırmasında Ağ ve Öğrenme Katsayısı Bazlı Etkisi (Network and Learning Coefficient Based Effect of Data Augmentation on Dataset Classification)

kullanılan verilerin sınıflandırılmasında yüksek bir performans gösterdiğini ve domates yapraklarında oluşan 9 farklı hastalığın ve sağlıklı domates yapraklarının tespit edilerek sınıflandırılmasında yardımcı bir yöntem olarak kullanılabilirliğini göstermektedir. Önerilen ESA modeli (T-LeafNet), maliyeti yüksek kaynaklara ve dolayısıyla daha hızlı çalışması için farklı birimlere (GPU, ayrılmış sunucu mimarisi vs.) ihtiyacı olan çok katmanlı sinir ağlarına göre daha az düzeyde donanım ihtiyaçları gerektirmektedir. Bu durumun sebebi, genellikle kullanılanlara göre, daha az filtre boyutuna, daha az miktarda katmana ve daha küçük boyutlu olan eğitim verilerinin kullanılmasından kaynaklı, daha az parametreye ihtiyaç duyulmasıdır. Son dönemlerde ortaya çıkan modellerin aksine, model GPU'ya gerek kalmadan CPU üzerinden de eğitilebilecek boyutlarda tasarlanmış, elde edilen başarımları bu çerçevede daha derin ağları geçmesi de kaynak tüketimi, mobil ortamlara adaptasyonunun mümkün olması gibi nedenlerden dolayı ön plana çıkmaktadır. Model, domates bitkisinde oluşan önemli 9 farklı hastalığın tespitinde etkili ve basit bir yöntem sağlamaktadır. Az miktarda veri ile elde edilen model, geleneksel son teknoloji tekniklerle karşılaştırmalı sonuçlar vermektedir.

Şekil 6'da AlexNet, MobileNetV2, VGG16 ve T-LeafNet üzerinde yapılan eğitimler sonucunda test kümesinin sınıflandırılmasında elde edilen karışıklık matrisleri verilmiştir. Verilen modeller Tablo 1'de koyu olarak belirtilen, modellere ait en yüksek başarımları elde edilmiş parametrelere sahip ağların sonuçlarıdır. Sol üst şekilde T-LeafNet başarımları, sağ üst şekilde AlexNet, sol alttaki şekilde MobileNetV2 ve son olarak sağ alttaki şekilde de VGG16 modellerine ait karışıklık matrisi verilmiştir. Tablo 2'de ise Şekil 6'ya göre türetilmiş karışıklık matrisi tabanlı performans metrikleri açısından sınıflandırıcı değerlendirmeleri verilmiştir. Her mimari için kesinlik, duyarlılık, F1 skor, doğruluk oranı ve kappa değerleri hesaplanarak tabloda sunulmuştur. Verilen karışıklık matrislerinde en başarılı mimarinin VGG16 olduğu görülmektedir. Sınıf bazında bakıldığında VGG16 mimarisinde Geç Yanıklık hastalığında tabloda da görüldüğü üzere %100 duyarlılık ve %99,7 kesinlik değeri elde edilmiştir. Sağlıklı yapraklarda ise %100 duyarlılık ve %99,4 değerli kesinlik değeri elde edilmiştir. Kesinlik ve duyarlılık değerleri birlikte en yüksek olan sınıflar veri eğitimi sonucunda en fazla verim alınan sınıflardır. Performansları karşılaştırılan mimariler arasında Geç Yanıklık hastalığını en doğru sınıflandıran mimari VGG16'dır. %99,21 değerinde doğruluk ve 0,99 değerinde kappa değeri elde edilmiştir. T-LeafNet'e bakıldığında duyarlılık değeri %100 olan sınıflar Mozaik Virüs ve Sağlıklı yaprak sınıflarıdır. Kesinlik değeri Mozaik Virüs'te %98,81 ve Sağlıklı yapraklarda %96,71'dir. %97,32'lik doğruluk oranı ve 0,97 değerinde kappa değeri bulunmuştur. Üzerinde kısa sürede eğitim yapılan T-LeafNet modelinde, alt hastalık sınıflarına bakılmadan -sadece sağlıklı ve

genel hastalıklı yaprak olarak- yapılan sınıflandırmada sağlıklı ve hastalıklı yaprak sınıflarında %100 başarı vermesi T-LeafNet ağının kullanılmasında önemli bir nokta oluşturmıştır. Tablo incelendiğinde, Mozaik Virüs Hastalığının daha yüksek doğrulukla tahmin edilebildiği görülmektedir. Mozaik Virüs hastalığında %100 kesinlik, duyarlılık ve F1 skor sonucu veren MobileNetV2 göze çarpmaktadır. Bu durum, mimariye verilen bir veri kümesinde Mozaik Virüs sınıfını %100 doğrulukta ayırt edilebileceğini göstermektedir. Tablo üzerinde MobileNetV2 incelendiğinde Yaprak Küfü sınıfında %100 kesinlik ve %99,8 değerinde duyarlılığa sahip olduğu görülmektedir. Bu durum Yaprak Küfü hastalığının da MobileNetV2 mimarisi ile yüksek doğruluk sonucuyla ayırt edilebileceğini göstermektedir. Ağ üzerinde %99,1 değerinde genel doğruluk oranı ve 0,99 değerli kappa sonucu elde edilmiştir. Son olarak şekil üzerinde AlexNet'e bakıldığında hiçbir hastalık üzerinde %100 kesinlik ya da duyarlılık vermediği görülmektedir. Ancak %98,32 değerinde doğruluk sonucu ve 0,98 değerli kappa sonucu verdiği için domates hastalık sınıflandırma işlemlerinde rahatça kullanılabilirliği kanıtlanmıştır.

Öğrenme aktarımı, yapay öğrenme sistemlerinin eğitim sayesinde öğrendiği bilgileri benzer ya da farklı problem çözümlerinde kullanılmasını inceleyen öğrenme yaklaşımıdır [37]. Öğrenme aktarımı tabanlı yapılan modellerin yüksek doğruluk oranı vermelerinin nedeni, önceden öğrenilen bilgileri yeni sorunlarda kullanabilmeleridir. Çalışmada ayrıca ağların eğitim süreleri kıyaslanmak için kaydedilmiştir. Modellerin, k katlamalı çapraz doğrulama tekniği kapsamında ortalama eğitim süreleri Tablo 3'te gösterilmiştir. Eğitim aşamasında, Intel i5 10400 CPU mimarisine sahip, 16GB dahili hafıza modülü içeren ve Geforce RTX 2060 (6GB) GPU birimi bulunan bilgisayar kullanılmıştır. Ayrıca deneyler Matlab 2020a platformu üzerinde gerçekleştirilmiştir [38]. CUDA çekirdeklerine sahip gelişmiş GPU mimarisi pek çok platformlarda yer almadığından, süre kıyaslamasında modellerin eğitimi, GPU ve CPU üzerinde ayrı ayrı gerçekleştirilmiş ve tabloya kaydedilmiştir. Böylelikle kullanılan modellerin CPU merkezli eğitiminin de gerçekleştirilebileceği araştırılmıştır. GPU tabanlı eğitim süreçlerinin analizlerinde, en hızlı eğitimin T-LeafNet üzerinde yapıldığı gözlenmiştir. Orijinal veri kümesinde katlama başına 75 dakikada, artırılmış veri kümesinde 93 dakikada eğitim süreci tamamlanmıştır. AlexNet mimarisinde orijinal veri kümesinde ortalama 102 dakika ve artırılmış veri kümesinde 137 dakika eğitim sürmüştür. Mobil platformlar için özel tasarlanmış bir ağ olan MobileNetV2'de, katlama başına eğitim ortalama 341 dakika ve artırılmış veri kümesinde 432 dakika sürmüştür. Son olarak VGG16 mimarisi üzerindeki süreler hesaplanmış ve orijinal veri kümesi ve artırılmış veri kümesinde eğitimler sırasıyla her katlama içine 658 dakika ve 746 dakika sürmüştür. CPU kullanılarak gerçekleştirilen eğitim

		Tahminlenen Sınıf										Tahminlenen Sınıf									
Gerçek Sınıf	B.L.	968	14	4		8		2	2		2	989		2		2	1	2	3	1	
	E.Y.	9	958	22	1	3		2	2	2	1	11	959	9	2	1		9	8		1
	G.Y.	2	19	967		1	4	2	1	2	2	2	9	971		2	6	4	2	1	3
	M.V.				1000										998						2
	S.Y.K.	9	2	2		981						12				982					6
	S.						1000							1			998		1		
	S.Y.L.	4	4	9	8			961	3	7	4	1	2	3	1			990	3		
	Y.B.		4	2	1		19	5	948	1	20		5				11	3	965		16
	Y.K.					3				990	7						11		987	2	
	Ö.A.			2	2	4	11	1	17	4	959				1	1			5		993
Gerçek Sınıf	B.L.	990		2				4	4			990	4		1			1		3	1
	E.Y.	1	985	3			1	8	2			2	979		6	1	1	2	1	7	1
	G.Y.	3	7	981		1	4	3	1					1000							
	M.V.				1000							1	11	3	983			1			1
	S.Y.K.	6				992			1	1		6			1	993	1	2	2	1	
	S.			1			999										1000				
	S.Y.L.		2				1	996	1				2			2	4	988		4	
	Y.B.						2	7	989		2								996	4	
	Y.K.							1		998	1				1			1		998	
	Ö.A.		1								980	4								2	994

Şekil 6. En İyi Başarım Veren Ağların Karışıklık Matrisleri: Artırılmış Veri Kümesi Üzerinde T-LeafNet Başarımı (Sol Üst), Artırılmış Veri Kümesi Üzerinde AlexNet Başarımı (Sağ Üst), Artırılmış Veri Kümesi Üzerinde MobileNetV2 Başarımı (Sol Alt), Artırılmış Veri Kümesi Üzerinde VGG16 Başarımı (Sağ Alt) (B.L.: Bakteriye Leke, E.Y.: Erken Yanıklık, G.Y.: Geç Yanıklık, M.V.: Mozaik Virüs, S.Y.K.: Sarı Yaprak Kıvrıkcılığı, S.: Sağlıklı, S.Y.L.: Septorya Yaprak Lekesi, Y.B.: Yaprak Beneği, Y.K.: Yaprak Küfü, Ö.A.: Örümcek Akarı)

(Confusion Matrices of Best Performing Networks: T-LeafNet Performance on Augmented Dataset (Top Left), AlexNet Performance on Augmented Dataset (Top Right), MobileNetV2 Performance on Augmented Dataset (Bottom Left), VGG16 Performance on Augmented Dataset (Bottom Right) (B.L.: Bacterial Spot, E.Y.: Early Blight, G.Y.: Late Blight, M.V.: Mosaic Virus, S.Y.K.: Yellow Leaf Curl, S.: Healthy, S.Y.L.: Septoria Leaf Spot, Y.B.: Target Spot, Y.K.: Leaf Mold, Ö.A.: Spider Mite))

Tablo 2. Şekil 6'dan Türetilen Karışıklık Matrisi Tabanlı Performans Metrikleri Açısından En İyi Sınıflandırıcıların Değerlendirilmesi (B.L.: Bakteriye Leke, E.Y.: Erken Yanıklık, G.Y.: Geç Yanıklık, M.V.: Mozaik Virüs, S.Y.K.: Sarı Yaprak Kıvrıkcılığı, S.: Sağlıklı, S.Y.L.: Septorya Yaprak Lekesi, Y.B.: Yaprak Beneği, Y.K.: Yaprak Küfü, Ö.A.: Örümcek Akarı)
(Evaluation of the Best Classifiers for Confusion Matrix Based Performance Metrics Derived from Figure 6 (B.L.: Bacterial Spot, E.Y.: Early Blight, G.Y.: Late Blight, M.V.: Mosaic Virus, S.Y.K.: Yellow Leaf Curl, S.: Healthy, S.Y.L.: Septoria Leaf Spot, Y.B.: Target Spot, Y.K.: Leaf Mold, Ö.A.: Spider Mite))

		B.L.	E.Y.	G.Y.	M.V.	S.Y.K.	S.	S.Y.L.	Y.B.	Y.K.	Ö.A.
T-Leaf Net	Kesinlik	97,6	95,7	95,9	98,8	98,1	96,7	98,8	97,4	98,4	95,8
	Duyarlılık	96,8	95,8	96,7	100	98,1	100	96,1	94,8	99	95,9
	F1 Skor	97,2	95,7	96,3	99,4	98,1	98,3	97,4	96,1	98,7	95,8
	Doğruluk	97,32									
	Kappa	0,97									
AlexNet	Kesinlik	97,4	98,4	98,8	99,6	99,4	98,2	97,2	97,8	99,8	97,1
	Duyarlılık	98,9	95,9	97,1	99,8	98,2	99,8	99	96,5	98,7	99,3
	F1 Skor	98,2	97,1	97,8	99,7	98,8	99	98,1	97,1	99,2	98,2
	Doğruluk	98,32									
	Kappa	0,981									
MobileNet V2	Kesinlik	99	99	99,4	100	99,9	99	97,6	97,5	100	99,6
	Duyarlılık	99	98,5	98,1	100	99,2	99,9	99,6	98,9	99,8	98
	F1 Skor	99	98,7	98,7	100	99,5	99,4	98,6	98,2	99,9	98,8
	Doğruluk	99,1									
	Kappa	0,99									
VGG16	Kesinlik	99,3	98,3	99,7	99,1	99,7	99,4	99,3	99,5	98,1	99,7
	Duyarlılık	99	97,9	100	98,3	99,3	100	98,8	99,6	99,8	99,4
	F1 Skor	99,1	98,1	99,8	98,7	99,5	99,7	99	99,5	99	99,5
	Doğruluk	99,21									
	Kappa	0,991									

analizlerinde ise süreler önerilen derin ağ modeli olan T-LeafNet dışında çok uzun sürelerde tamamlanmıştır. Bunun nedeni ağların sadece özel olarak domates yaprakları için tasarlanmamış olması, dolayısıyla daha fazla farklı probleme yönelik olduklarından daha

karmaşık yapılara sahip olması ve parametrelerinin çok fazla olmasından kaynaklıdır. VGG16 mimarisinde 13 evrimsel katman ve 3 tam bağlantılı katman kullanılmaktadır. Mimaride kullanılan katman ve kullanılan parametre sayısı yüksek olduğu için eğitim

süresinin aşırı uzun sürdüğü kaydedilmiştir ve CPU üzerinde çok uzun süren eğitimden dolayı sonuç alınamamıştır. Mobil uygulamalarda kullanılmak üzere geliştirilen MobileNetV2 ise yapısından kaynaklı olarak yine uzun süren bir eğitim aşamasına sahip olmuştur. AlexNet'in yapısı VGG16'ya göre daha küçüktür. Buna rağmen eğitim süresi T-LeafNet'e göre daha uzun sürmüştür. T-LeafNet mimarisi,

başarım oranının diğer ağlarla kıyaslanabilir seviyede yüksek olması ve eğitim süresinin önceden eğitilmiş ağlara göre çok daha kısa olması yönünden öne çıkmaktadır. Modellerin CPU üzerinde eğitilebilir süreleri analiz edildiğinde, T-LeafNet en kısa süre olarak 217 ve 272 dakika eğitim süreleri için normal ve artırılmış veri kümelerinde yine ön plana çıkmaktadır. Yapılan çalışmada T-LeafNet modeli daha

Tablo 3. Derin Öğrenme Modellerinin Ortalama Katlama Başlı Eğitim Süreleri (\pm Katlama Arası Standart Sapma)
(Average Training Times per Fold of Deep Learning Models (\pm Standard Deviation Between Folds))

	Orijinal Veri Kümesi		Artırılmış Veri Kümesi	
	GPU	CPU	GPU	CPU
T-LeafNet	75 (\pm 4) dakika	217 (\pm 14) dakika	93 (\pm 3) dakika	272 (\pm 18) dakika
AlexNet	102 (\pm 3) dakika	468 (\pm 23) dakika	137 (\pm 2) dakika	523 (\pm 37) dakika
MobileNetV2	341 (\pm 6) dakika	1282 (\pm 52) dakika	432 (\pm 8) dakika	1479 (\pm 132) dakika
VGG16	658 (\pm 9) dakika	Ölçülemedi	746 (\pm 11) dakika	Ölçülemedi

Tablo 4. T-LeafNet, AlexNet, MobileNetV2 ve VGG16 Modellerinin T-LeafNet Eğitim Süreleri Baz Alınarak Sınırlandırıldığı Eğitim Süresindeki Başarıları
(Accuracy Rates of T-LeafNet, AlexNet, MobileNetV2 and VGG16 Models Which Is Limited Based on T-LeafNet Training Periods)

	Orijinal Veri Kümesi		Artırılmış Veri Kümesi	
	GPU (75 dk.)	CPU (217 dk.)	GPU (93 dk.)	CPU (272 dk.)
T-LeafNet	97,32	97,02	94,96	94,66
AlexNet	91,77	67,91	92,38	69,1
MobileNetV2	67,18	38,31	55,26	32,58
VGG16	43,84	28,86	24,7	21,13

Tablo 5. Literatürdeki Domates Yaprak Hastalığı Sınıflandırma Çalışmalarından Örnekler
(Examples from Tomato Leaf Disease Classification Studies in the Literature)

Makale	Kullanılan Yöntemler	Sınıf Sayısı	Açıklama	Doğruluk Oranı
Mokhtar vd. 2014 [2]	Ön İşleme GLCM ile Özellik Çıkarma SVM Sınıflandırma	2	800 adet hastalıklı ve sağlıklı domates yaprak görüntüsünün olduğu bir veri kümesi kullanılmıştır. Model, sadece hastalıklı ve sağlıklı domates yaprağı ayrımı üzerine eğitilmiştir.	%99,83
Zhang vd. 2018 [3]	Veri Artırma SGD ve Adam Optimizasyonu AlexNet, GoogLeNet ve ResNet ile Öğrenme Aktarımı	9	PlantVillage veri kümesinde bulunan; sağlıklı domates yaprağı ve 8 ayrı domates yaprak hastalığı içeren 5550 adet alt veri kümesi görüntüleri üzerinde çalışılmıştır.	%97,28 (ResNet)
Zaki vd. 2020 [21]	MobileNetV2 ile Öğrenme Aktarımı	4	PlantVillage veri kümesinden alınan 3 tür domates yaprak hastalığı ve bir sağlıklı yaprak sınıfı olmak üzere toplamda 4671 veri üzerinde çalışılmıştır.	%90
Wagle vd. 2021 [8]	Veri Artırma AlexNet, VGG16, GoogLeNet, MobileNetV2 ve SqueezeNet ile Öğrenme Aktarımı	9	PlantVillage veri kümesinde bulunan; sağlıklı domates yaprağı ve 8 ayrı domates yaprak hastalığı içeren alt veri kümesi görüntüleri üzerinde çalışılmıştır.	%99,17 (VGG16)
Wu vd. 2021 [13]	Ön İşleme Mask R-CNN ile Tespit ve Sınıflandırma Modeli Oluşturma	10	PlantVillage veri kümesinde bulunan; sağlıklı domates yaprağı ve 9 ayrı domates yaprak hastalığı içeren 18160 adet alt veri kümesi görüntüleri üzerinde Derin ESA modelleri ile çalışılmıştır.	%94,17
Tan vd. 2021 [14]	Veri Artırma LBP ve GLCM ile Özellik Çıkarma K-NN, RF ve SVM Sınıflandırma AlexNet, VGG16, ResNet34, EfficientNet-b0 ve MobileNetV2 ile Öğrenme Aktarımı	10	PlantVillage veri kümesinde bulunan; sağlıklı domates yaprağı ve 9 ayrı domates yaprak hastalığı içeren alt veri kümesi görüntüleri üzerinde çalışılmıştır.	%99,7 (ResNet34)
Önerilen Çalışma	Veri Artırma AlexNet, MobileNetV2 ve VGG16 ile Öğrenme Aktarımı Özel ESA Modeli (T-LeafNet) Oluşturma	10	Hepsinden 1000 adet olmak üzere 9 farklı domates yaprak hastalığı ve 1 sağlıklı domates yaprak sınıfı olarak toplamda 10000 görüntü içeren "Tomato Leaf Disease Detection" isimli veri kümesi üzerinde çalışılmıştır.	%97,32 (T-LeafNet)

düşük sonuç vermesine rağmen Tablo 3'te verilen süreler kıyaslandığında daha kısa eğitim süresi ile ön plana çıkmaktadır. Objektif bir kıyaslama sunabilmek adına, literatürde daha yüksek sınıflandırma doğruluğu veren ayrıca bu çalışmada da değerlendirilen AlexNet, MobileNetV2 ve VGG16 gibi daha büyük modellerin T-LeafNet ile aynı eğitim sürelerinde sınıflandırma performansları GPU ve CPU üzerinde eğitim süreleri bazında Tablo 4'te raporlanmıştır. Tablo 4 üzerindeki sınıflandırma doğrulukları orijinal veri kümesi temelinde GPU ve CPU kullanılan mimariler için sırası ile 75 ve 217 dakika olarak sabitlenmiştir. Artırılmış veri kümesinin sınıflandırılmasında ise GPU ve CPU üzerindeki eğitimler 93 ve 272 dakika ile sınırlandırılmıştır. Elde edilen sonuçlar doğrultusunda, önerilen T-LeafNet derin öğrenme modelinin daha kısa sürede daha yüksek doğruluk ile domates yaprak hastalığı veri kümesini sınıflandırdığı görülmüştür. Ayrıca CPU üzerinde eğitimi gerçekleştirilen çok katmanlı derin öğrenme ağlarının eğitimlerinin, sınırlandırılan 217 ve 272 dakikalarda hiç gerçekleşmediği, bu nedenle çok daha düşük sonuçlar üretildiği gözlemlenmiştir. Diğer yandan önerilen modelin CPU üzerinde de kısa sürede eğitiminin tamamlandığı ve yüksek doğruluk oranları ile sınıflandırmayı gerçekleştirdiği Tablo 4'de gösterilmiştir.

Önerilen çalışma kısa eğitim süresi ve yüksek sınıflandırma performansı ile ön plana çıkmaktadır. Tablo 5'te domates yaprak hastalıklarını sınıflandırma yönteminde T-LeafNet modeli ile literatürdeki domates veri kümeleri ile yapılan çalışmalar verilmiştir. Literatürde bulunan veri kümeleri içerisindeki domates yaprak hastalıklarının bireysel başarıları bu tablo üzerinde doğruluk oranı başlıklı kısımda gösterilmiştir. Önerilen çalışma haricinde, farklı yöntemler ile yapılan çalışmalarda doğruluk oranı en yüksek olan modelin sonuçları tabloya işlenmiştir.

4. Sonuçlar ve Gelecek Çalışmalar (Conclusion and Future Work)

Domates yetiştiriciliği, Türkiye'deki en gelişmiş sektörlerden biridir ve ekonomiye yüksek oranda katkı sağlamaktadır. Ayrıca insanların tüketimine sunulan temel gıdalardan biri olduğu için büyük miktarlarda yetiştiriciliği yapılmaktadır. Domateslerin verimli olması, sağlıklı bir şekilde büyümesi bu hususta çok büyük önem taşımaktadır. Bu nedenle, domates bitkisinde en yaygın dokuz hastalık tespitinin yapılması amaçlanmıştır. Bu hastalıklar da domates yapraklarından tespit edildiği için yapılan işlemler domates yapraklarının görüntü verilerinin olduğu veri kümesi üzerinden gerçekleştirilmiştir. Önerilen bu çalışmada "Tomato Leaf Disease Detection" veri kümesindeki veriler kullanılarak farklı derin öğrenme modellerinin, domates yaprak hastalıkları konusunda sınıflandırma performansları kıyaslanmıştır. Derin öğrenme ağlarının uzun eğitim süreleri ve yüksek kaynak kullanımının aksine, düşük sistem kaynaklarını kullanarak, daha kısa eğitim süreleri içerisinde yüksek sınıflandırma performansı veren ESA mimarisi önerilmiştir. Domates yaprak hastalıkları kapsamında özel olarak tasarlanan ve T-LeafNet ismi verilen ESA mimarisindeki sonuçlar öğrenme aktarımı yöntemindeki AlexNet, MobileNetV2 ve VGG16 mimarileriyle karşılaştırılmıştır. Önerilen mimari 10 farklı domates sınıfının - sağlıklı, septorya yaprak lekesi, sarı yaprak kıvrıcılığı, bakteriyel leke, erken yanıklık, geç yanıklık, yaprak küfü, mozaik virüs, örümcek akarı ve yaprak beneği- doğru şekilde belirlenmesi amacıyla oluşturulmuş, kıyaslanan diğer ağlara nazaran daha az sayıda katmandan oluşan, sistem kaynaklarını minimum kullanan ve kısa eğitim süreleri içeren evrişimli sinir ağıdır. Kullanılan veri kümesinde toplamda 10000 görüntü üzerinde T-LeafNet mimarisinde %97,32, VGG16 mimarisinde %99,21, AlexNet mimarisinde %98,32 ve MobileNetV2 mimarisinde ise %99,1 doğruluk oranı verdiği görülmüştür. Önerilen modelin sınıflandırma performansı kıyaslandığında geliştirilebilir olduğu gözlemlenmiş ancak eğitim süresinin çok kısa olması modelin ön plana çıkmasını sağlamıştır.

Yapılan önceki çalışmalara göre daha az eğitim süreleri ve işlem ile kıyaslanabilir yüksek doğruluk oranları elde edilmiştir. Gelecek dönemde yapılacak çalışmalara ilham verebilecek olan bu çalışma, daha fazla veri içeren bir veri kümesi ile daha yüksek doğruluk oranı alınacak şekilde geliştirilebilir. Bu sayede önerilen model, domates yetiştiriciliği yapan kişiler tarafından daha rahat hastalık tespiti yapabilmek için kullanılabilir. Yaklaşık %99'luk doğruluk oranıyla önerilmiş olan model, maliyeti düşük bir hesaplamayla domates yapraklarındaki hastalıkların tespitine yardımcı olabilir. Farklı yaprak türlerinin tek modelle tespiti için yapılacak yeni çalışmalarda domates yapraklarının yüksek doğruluk oranıyla tespit edilmesini sağlayabilir. Ayrıca ilerleyen zamanlarda geliştirilecek olan ortak karar mekanizmalarının oluşturulmasına da yüksek oranda katkı sağlayabileceği düşünülmektedir. Ayrıca, sunulan çalışmada elde edilen MobileNetV2 sınıflandırma performansları, MobileNet tabanlı bir mobil uygulama geliştirilebilmesinin analizleri pratiklik ve modülerlik anlamında daha kolaylaştırılabileceğini ve yüksek doğruluk ile analizlerin mümkün olabileceğini göstermiştir. Ayrıca, T-LeafNet tabanlı sınıflandırma başarımlarının MobileNetV2 ağına yakın olması, önerilen yaklaşımın mobil uygulamalara da adapte edilebileceğini ortaya çıkarmıştır.

Yapılan eğitimlerde, kullanılan domates yaprağı görüntü kümesi ne kadar geniş olursa o kadar fazla vakit alacaktır. Tarım ürünleri, kendilerine uygun olan iklim ve mevsimlerde yetiştirilebildikleri için domates yapraklarının hastalıklarının tespiti için yapılan eğitimin süresi ne kadar kısa olursa tarımdaki verimlilik o kadar artacak ve maliyeti o derece düşecektir. Bu yüzden T-LeafNet ağına daha kısa zamanda yüksek sonuçlu olarak yaptığı eğitim diğer öğrenmenin aktarımında kullanılan modellere göre daha fazla ön plana çıkmaktadır.

Kaynaklar (References)

1. TEPGE, "Tarım Ürünleri Piyasaları," Ankara, Haziran 2021.
2. Mokhtar U., Bendary N.E., Hassenian A.E., Emary E., Mahmoud M.A., Hefny H., Tolba M.F., SVM-Based Detection of Tomato Leaves Diseases, Intelligent Systems'2014, Warsaw-Poland, 641-652, 24-26 Eylül, 2014.
3. Zhang K., Wu Q., Liu A., Meng X., Can Deep Learning Identify Tomato Leaf Disease? Advances in Multimedia, 2018, 1-10, 2018.
4. He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas-NV-USA, 770-778, 27-30 Haziran, 2016.
5. Krizhevsky A., Sutskever I., Hinton G.E., ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems 25: 26th Annual Conference on Neural Information Processing Systems 2012 (NIPS 2012), Lake Tahoe-Nevada-USA, 84-90, 3-6 Aralık, 2012.
6. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., Going Deeper with Convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston-MA-USA, 1-9, 7-12 Haziran, 2015.
7. Kingma D., Ba J., Adam: A method for stochastic optimization, 3rd International Conference on Learning Representations (ICLR) 2015, San Diego-CA-USA, 7-9 Mayıs, 2015.
8. Wagle S.A., R. H., A Deep Learning-Based Approach in Classification and Validation of Tomato Leaf Disease, Traitement du Signal, 38 (3), 699-709, 2021.
9. David P. Hughes, Marcel Salathe. An open access repository of images on plant health to enable the development of mobile disease diagnostics through machine learning and crowdsourcing. <https://arxiv.org/abs/1511.08060>. Yayın tarihi Kasım 25, 2015. Güncelleme tarihi Nisan 12, 2016. Erişim tarihi Eylül 22, 2021.
10. Simonyan K., Zisserman A., Very Deep Convolutional Networks for Large-Scale Image Recognition, 3rd International Conference on Learning Representations (ICLR) 2015, San Diego-CA-USA, 7-9 Mayıs, 2015.

11. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.-C., MobileNetV2: Inverted Residuals and Linear Bottlenecks, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City-UT-USA, 4510-4520, 18-23 Haziran, 2018.
12. Forrest N. Iandola, Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally, Kurt Keutzer. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. <https://arxiv.org/abs/1602.07360>. Yayın tarihi Şubat 24, 2016. Güncelleme tarihi Kasım 4, 2016. Erişim tarihi Eylül 22, 2021.
13. Wu Y., Xu L., Goodman E.D., Tomato Leaf Disease Identification and Detection Based on Deep Convolutional Neural Network, *Intelligent Automation & Soft Computing*, 28 (2), 561-576, 2021.
14. Tan L., Lu J., Jiang H., Tomato Leaf Diseases Classification Based on Leaf Images: A Comparison between Classical Machine Learning and Deep Learning Methods, *AgriEngineering*, 3 (3), 542-558, 2021.
15. Barbedo, J.G.A., A novel algorithm for semi-automatic segmentation of plant leaf disease symptoms using digital image processing, *Tropical Plant Pathology*, 41, 210-224, 2016.
16. Pearline S.A., Kumar S., Harini S., A study on plant recognition using conventional image processing and deep learning approaches, *Journal of Intelligent & Fuzzy Systems*, 36, 1-8, 2019.
17. Munisami T., Ramsurn M., Kishnah S., Pudaruth S., Plant leaf recognition using shape features and colour histogram with k-nearest neighbour classifiers, *Procedia Computer Science (Elsevier)*, 58, 740-747, 2015.
18. Wu S.G., Bao F.S., Xu E.Y., Wang Y.-X., Chang Y.-F., Xiang Q.-L., A leaf recognition algorithm for plant classification using probabilistic neural network, 2007 IEEE International Symposium on Signal Processing and Information Technology, Le Meridien Pyramids-Cairo-Egypt, 11-16, 15-18 Aralık, 2007.
19. Söderkvist, O., Computer vision classification of leaves from swedish trees, Master Tezi, Linköping University, Department of Electrical Engineering, Computer Vision, Linköping University, The Institute of Technology, İsveç, 2001.
20. Mohanty S.P., Hughes D.P., Salathé M., Using Deep Learning for Image-Based Plant Disease Detection, *Frontiers in Plant Science*, 7, 2016.
21. Zaki S.Z.M., Zulkifley M.A., Stofa M.M., Kamari N.A.M., Mohamed N.A., Classification of tomato leaf diseases using MobileNet V2, *IAES International Journal of Artificial Intelligence (IJ-AI)*, 9 (2), 290-296, 2020.
22. Hasan M., Tanawala B., Patel K.J., Deep Learning Precision Farming: Tomato Leaf Disease Detection by Transfer Learning, *SSRN Electronic Journal*, 2019.
23. Şafak E., Doğru İ., Barışçı N., Toklu S., IoT based mobile driver drowsiness detection using deep learning, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (4), 1869-1882, 2022.
24. Karasulu B., Yücalar F., Borandağ E., A hybrid approach based on deep learning for gender recognition using human ear images, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (3), 1579-1594, 2022.
25. Duman B., Özsoy K., A deep learning-based approach for defect detection in powder bed fusion additive manufacturing using transfer learning, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (1), 361-376, 2022.
26. Kohavi R., A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection, *International Joint Conference on Artificial Intelligence (IJCAI)*, 14, 1137-1145, 1995.
27. Shorten, C., Khoshgoftaar, T.M., A survey on Image Data Augmentation for Deep Learning, *Journal of Big Data*, 6 (1), 1-48, 2019.
28. Chen Y., Jiang H., Li C., Jia X., Ghamisi P., Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks, *IEEE Transactions on Geoscience and Remote Sensing*, 54 (10), 6232-6251, 2016.
29. Wang S.-H., Xie S., Chen X., Guttery D.S., Tang C., Sun J., Zhang Y.-D., Alcoholism Identification Based on an AlexNet Transfer Learning Model, *Frontiers in Psychiatry*, 10, 2019.
30. Wu Y., Qin X., Pan Y., Yuan C., Convolution Neural Network based Transfer Learning for Classification of Flowers, 2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP), Shenzhen-China, 562-566, 13- 15 Temmuz, 2018.
31. İlhan H.O., Sigirci I.O., Serbes G., Aydın N., A fully automated hybrid human sperm detection and classification system based on mobile-net and the performance comparison with conventional methods, *Medical & Biological Engineering & Computing*, 58 (5), 1047-1068, 2020.
32. Pawara P., Okafor E., Surinta O., Schomaker L., Wiering M., Comparing Local Descriptors and Bags of Visual Words to Deep Convolutional Neural Networks for Plant Recognition, 6th International Conference on Pattern Recognition Applications and Methods, Porto-Portugal, 479-486, 24 Şubat, 2017.
33. Deng J., Dong W., Socher R., Li L.-J., Li K., Li F.-F., ImageNet: A large-scale hierarchical image database, 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami-FL-USA, 248-255, 20-25 Haziran, 2009.
34. Howard A.G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H., MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications, <https://arxiv.org/abs/1704.04861>. Yayın tarihi Nisan 17, 2017. Erişim tarihi Eylül 22, 2021.
35. Agarwal M., Singh A., Arjaria S., Sinha A., Gupta S., Toled:Tomato leaf disease detection using convolution neural network, *Procedia Computer Science (Elsevier)*, 167, 293-301, 2020.
36. Dankers F.J.W.M., Traverso A., Wee L., van Kuijk S.M.J., Prediction Modeling Methodology, *Fundamentals of Clinical Data Science*, Editör: Kubben P., Dumontier M., Dekker A., Springer International Publishing, Cham (CH), 101-120, 2019.
37. Fırıldak K., Talu M.F., Evrişimsel Sınır Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi, *Bilgisayar Bilimleri*, 4 (2), 88-95, 2019.
38. MATLAB Version 9.8.0.1323502 (R2020a), The Mathworks, Inc., Natick, Massachusetts (2020).

