



Sınıflandırma Probleminde Derin Özellik Birleştirme Yaklaşımıyla Domates Yaprağı Görüntülerinde Hastalık Tespiti

Serdar Ertem¹, Erdal Özbay^{2*}

¹Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-2921-5673), serdarertem01@gmail.com

^{2*}Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0002-9004-4802), erdalozbay@firat.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI:10.31590/ejosat.1216380)

ATIF/REFERENCE: Ertem, S. & Özbay, E. (2022). Sınıflandırma Probleminde Derin Özellik Birleştirme Yaklaşımıyla Domates Yaprağı Görüntülerinde Hastalık Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 84-92.

Öz

Domates, yaşadığımız coğrafya ve dünyanın birçok yerinde üretimi yapılan ve en çok tüketilen önemli sebze türlerindedir. Domates üretiminde verim ve kaliteyi olumsuz yönde etkileyen en önemli faktörlerin başında zararlı organizma olarak adlandırılan hastalık gelmektedir. Domates, çevresel ve iklim faktörlerine bağlı olarak ekim sürecinin her aşamasında birçok hastalığa yakalanabilir. Bitki hastalıklarında yapılması gereken ilk şey hastalığın doğru tespit edilmesi ve gereken önlemlerin alınmasıdır. Bu çalışmada 9 hastalıklı ve 1 sağlıklı sınıftan oluşan toplam 18.160 domates yaprağı görüntüsü bulunan veri seti kullanılmıştır (Kaggle, 2021). Genel erişime açık Kaggle domates yaprağı hastalığı veri seti üzerinde deneysel sonuçlar elde edilmiştir. Analizler yapılırken veri seti, %80 eğitim ve %20 test verisi olarak ayrılmıştır. Çalışmada, Evrişimli Sinir Ağı (CNN) tabanlı DenseNet-201, ResNet-101 ve ShuffleNet modelleri kullanılarak domates yaprağı görüntülerinden 3000 adet öznetelik çıkarılmıştır. Bu çalışmada öznetelik sayısını düşürmek için Temel Bileşen Analizi (PCA) kullanılarak boyut indirgeme yapılmıştır. Domates yaprağındaki hastalıkları sınıflandırmak amacıyla Destek-Vektör Makinaları (SVM) algoritması kullanılmıştır. Eğitilen ağ mimarileri tek tek incelenmiştir. Bu incelemeler sonucunda mimarilerin doğruluk oranları AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet için sırası ile %93.5, %97.1, %91.0, %94.5, %97.4 ve %96.6 bulunmuştur. Yapılan analizlerden sonra doğruluk oranı yüksek olan DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilerek ve Temel Bileşen Analizi (PCA) kullanılarak boyut indirgeme yapılmıştır. Bu çalışmada yapılan sınıflandırma analizlerine göre en iyi performans gösteren Cubic SVM sınıflandırıcı ve One-vs-All Çok Sınıflı bileşen metodu ile %99.2 doğruluk oranına ulaşılmıştır. Literatür incelemeleri sonucunda domates yaprağı hastalık tespiti için bu çalışmanın etkili ve yüksek bir performans gösterdiği sonucuna ulaşılmıştır.

Anahtar Kelimeler: Domates yaprağı, CNN, SVM, PCA, Sınıflandırma.

Disease Detection in Tomato Leaf Images by Deep Feature Combination Approach in Classification Problem

Abstract

Tomato is one of the most important vegetable species produced and consumed mostly in the geography we live in and in many parts of the world. One of the most important factors that negatively affect yield and quality in tomato production is a disease called harmful organisms. Tomatoes can suffer from many diseases at every stage of the planting process, depending on environmental and climatic factors. The first thing to do in plant diseases is to correctly identify the disease and take the necessary precautions. In this study, a dataset with a total of 18.160 tomato leaf images consisting of 9 diseased and 1 healthy class was used (Kaggle, 2021). Experimental results were obtained on the publicly accessible Kaggle tomato leaf disease dataset. During the analysis, the data set was divided into 80% training and 20% test data. In the study, 3000 features were extracted from tomato leaf images by using Convolutional Neural Network (CNN) based DenseNet-201, ResNet-101, and ShuffleNet models. In this study, dimension reduction

*Sorumlu Yazar: erdalozbay@firat.edu.tr

was made using Principal Component Analysis (PCA) to reduce the number of features. Support-Vector Machines (SVM) algorithm was used to classify diseases in tomato leaves. The trained network architectures were examined one by one. As a result of these examinations, the accuracy rates of the architectures were found to be 93.5%, 97.1%, 91.0%, 94.5%, 97.4%, and 96.6% for AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101, and ShuffleNet, respectively. After the analysis, size reduction was made by combining DenseNet-201, ResNet-101, and ShuffleNet pre-trained network architectures with high accuracy and using Principal Component Analysis (PCA). According to the classification analyses made in this study, the Cubic SVM classifier and the One-vs-All Multi-Class component method, which performed the best, achieved 99.2% accuracy. As a result of the literature review, it was concluded that this study showed an effective and high performance for tomato leaf disease detection.

Keywords: Tomato leaf, CNN, SVM, PCA, Classification.

1. Giriş

Yeryüzünde çok fazla bitki türü olduğu bilinen bir gerçektir. Gün geçtikçe yeni bitki türleri keşfedilirken bazı bitki türlerinin de nesli tükenmektedir (Arivazhagan, Shebiah, Ananthi, & Varthini, 2013). Bu yok olan bitki türlerinin korunup gelecek kuşaklara aktarılabilmesi ekolojik denge bakımından hayati önem taşımaktadır. İklimsel değişiklikler, hava kirliliği, yetiştirme sürecinde bakteri, mantar ve virüs gibi nedenlerden dolayı bitkilerde hastalıklar oluşmaktadır. Bitkilerdeki görülen çoğu hastalığın teşhisi geleneksel yöntemlerle anlaşılmaktadır (Brahimi, Boukhalfa, & Moussaoui, 2017a).

Domates, yaşadığımız coğrafya ve dünyanın birçok yerinde üretimi yapılan ve en çok tüketilen önemli sebze türlerindedir. Domates üretiminde verim ve kaliteyi olumsuz yönde etkileyen en önemli faktörlerin başında zararlı organizma olarak adlandırılan hastalık gelmektedir. Domates, çevresel ve iklim faktörlerine bağlı olarak ekim sürecinin her aşamasında birçok hastalığa yakalanabilir. Bitki hastalıklarında yapılması gereken ilk şey hastalığın doğru tespit edilmesi ve gereken önlemlerin alınmasıdır.

Bitki üreticileri bu hastalıkları bilebilir fakat tanımlaması güçtür. Hastalığı bilse bile hastalığı tedavi etmek için uygulanması gereken metotlar hakkında bilgisi olmayabilir (Ferentinos, 2018; Sannakki, Rajpurohit, Sumira, & Venkatesh, 2013).

Teknolojinin ilerlemesiyle birlikte yapay zekâ uygulamaları zirai alanda hastalığın tespiti ve bitki türü sınıflandırmasında da rol almaya başlamıştır (Ferentinos, 2018). Yapay zeka metotları güvenilirliği yüksek ve seri sınıflandırma yapabilmesinden dolayı hem zamanı verimli kullanmayı sağlar hem de iş yoğunluğunu azaltması açısından avantaj sağlamaktadır (Arsenovic, Karanovic, Sladojevic, Anderla, & Stefanovic, 2019).

Domates, dünyada tüketiminin fazla olması nedeniyle büyük bir pazar payına sahiptir. Verimli domateslere sahip olmak için domates hastalıklarının önlemek şarttır. Bu çalışmada domates bitkisinin yapraklarında meydana gelen hastalıkların teşhisi için sınıflandırma yapılmıştır.

Renkli ve reel domates yaprağı görüntülerinden oluşan veri kümesi 10 sınıf ve 18160 tane görüntüden oluşmaktadır (Kaggle, 2021).


Yaygın domates bitkisi hastalıklarından erken yanıklık (Early blight), bu yaygın domates bitkisi hastalığı, bir bitkinin alt yapraklarında boğa gözü şeklinde kahverengi lekeler olarak ortaya çıkar. Genellikle lekelerin etrafındaki doku sararır. Sonunda, enfekte olmuş yapraklar bitkiden düşecektir. Çoğu durumda, hastalık belirtileri bitkide ilerlese bile domatesler olgunlaşmaya devam edecektir (Walliser, J., 2018).

Hastalıklı yaprak görüntülerinden bazıları Şekil 1'deki gibidir.



Şekil 1. Hastalıklı yaprak görüntüleri

Sağlıklı yaprak görüntülerinden bazıları Şekil 2'deki gibidir.



Şekil 2. Sağlıklı yaprak görüntüleri

Bu çalışmada ön eğitilmiş ESA algoritmalarından AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet mimarileri ile hastalığın tespiti ve sınıflandırma çalışması yapılmıştır. Bu mimarilerin sınıflandırma doğruluğu analiz edilmiştir. Bu değerlendirmeler sonucunda domates yaprağında oluşan hastalıkların tespiti için doğruluk oranı en yüksek CNN mimarileri birleştirilerek doğruluk oranı artırılmaya çalışılmıştır. Çalışma ile ilgili literatür taraması yapılmış, yapılan analizler hakkında ve elde edilen sonuçlar hakkında bilgiler verilmiştir.

2. İlgili Çalışmalar

Bu başlık altında bitki hastalıklarının tespiti konusunda yapılan sınıflandırma çalışmaları hakkında bilgiler verilmiştir.

Agarwal ve ark. Bir CNN mimarisi kullanılmıştır. 10 sınıflı bir veri kümesinde ortalama %91.2 doğruluk elde etmişler. Referans 5'te, PlantVillage veri kümesinden elde edilen yedi sınıftan oluşan domates yapraklarının görüntüleri Toalexnet ve VGG16 mimarileri olarak verilir. Görüntü numarası, mini parti boyutu ve önyargı gibi parametrelerin sınıflandırma doğruluğu üzerindeki etkisi gözlemlendi ve en iyi koşullar altında Alexnet ve VGG16 sırasıyla %97.29 ve %97.49'a ulaştı. Referans 6'da önerilen evrişim ağ yapısının performansını artırmak için görüntüye ön işleme uygulanmıştır. Sekiz gizli katmandan oluşan yöntem, ilgili veri kümesinde %98,4 başarı elde etti (Agarwal ve ark., 2020).

Cheng ve ark., tarımsal zararları tanımlamak için ResNet ve Alexnet kullanmışlardır. Aynı zamanda, SVM ve BP sinir ağları ile karşılaştırmalı deneyler yapmışlar; Sonuçta, ResNet-101 tarafından %98,67'lik en iyi doğruluğu elde etmişlerdir (Cheng ve ark., 2017). Liu ve diğ., 13.689 resimden, 4 sınıftan oluşan çalışmalarında AlexNet ve GoogleNet metotları ile %97,92

doğruluk oranları sonucuna ulaşmışlardır (Liu, Tang, Zhou, Meng, & Dong, 2016).

Arsenovic ve diğ., 139.011 görüntü ve 42 sınıfı olan veri setine AlexNet, VGG19, Inceptionv3, DenseNet201 ve ResNet152 mimarilerini uygulayarak %93,67 doğruluk oranı sonucunu bulmuşlardır (Arsenovic ve ark., 2019). Cheng ve Matson, ot ve pirinci tanımlamak için karar ağacı, destek vektör makinesi (SVM) ve sinir ağı kullanarak elde ettikleri en iyi doğruluk, % 98,2'dir (Cheng & Matson, 2015).

Mohanty ve diğ., AlexNet ve GoogleNet yöntemini kullanmış ve % 99,34 başarı oranı elde etmiştir. Çalışmada 38 sınıflı 54.308 görüntüden oluşan veri seti kullanmıştır (Mohanty, Hughes, & Salathé, 2016).

Geetharamani ve diğ., Derin Evrişimli Sinir Ağı yöntemini kullandığı 39arklı bitki yaprağı sınıfı ve arka plan görüntüsünden oluşan veri setinde %96,46 doğruluk oranı elde etmiştir (GeethaRamani, & ArunPandian, 2019).

Song vd., Sayısal görüntü işleme yöntemleri, destek vektör makineleri, yapay sinir ağları ve diğer birkaç teknik yardımıyla yaprak hastalıklarının tespiti ve sınıflandırılması yapılmıştır (Song vd., 2007, Chen vd., 2011, Qi vd., 2016, Xu vd., 2015). Song vd., farklı mısır yaprağı hastalıklarını %89.6 doğrulukla saptamak için bir SVM yöntemi uygulamışlardır (Song vd., 2007).

Shruthi ve ark., çalışmalarında bitki hastalıklarını tespit etmek ve sınıflandırmak için destek vektör makinelerini (SVM), yapay sinir ağlarını (YSA), k-en yakın komşu algoritmasını (k-NN), fuzzy sınıflandırıcıyı ve CNN mimarilerini kullanan çalışmalarını analiz etmişlerdir. Nihayetinde, CNN mimarileri kullanılarak yapılan sınıflandırmanın diğer dört sınıflandırma yöntemine göre daha yüksek doğrulukla daha fazla sayıda hastalık tespit ettiği sonucuna varmışlardır (Shruthi ve ark., 2019).

Sibiya ve ark., akıllı telefon kameraları tarafından toplanan mısır yaprağı hastalığı görüntülerini tanımak ve sınıflandırmak için bir CNN ağını eğiterek kullanmıştır. Araştırmada elde edilen %92,85'lik ortalama doğruluk değeri, CNN'in bu alanda uygulanabilirliğini göstermiştir (Sibiya & Sumbwanyambe, 2019). Al-Amin, patates yapraklarından patates hastalığını tahmin etmek için Evrişimli Sinir Ağı (CNN) modelini önermiştir (Al-Amin vd., 2019). Önerilen yaklaşım modelleriyle en yüksek %98,33 doğruluğa ulaşılmıştır.

Suryawati ve ark., Alexnet, GoogleNet ve VGGNet kullanarak modeli eğitmek için PlantVillage veri setinden domates yaprağı renkli görüntü örneklerini kullanmış ve sırasıyla %91.52, %89.68 ve %95.25 test doğruluğu elde etmişlerdir (Suryawati ve ark., 2018).

Tan ve ark., PlantVillage veri kümesi kullanılarak domates hastalığı sınıflandırmak için en doğru ML/DL modellerini belirlemeyi amaçlamıştır. Makine öğrenimi algoritması uygulaması için hastalık özelliklerini manuel olarak çıkarmak için farklı yöntemler kullanmışlardır. Çalışmalarında, yerel ikili desen (LBP) ve gri düzey birlikte oluşum matrisi (GLCM) yöntemlerini kullanarak toplam 52 doku özneteliği ve renk momenti ve renk histogramı yöntemlerini kullanarak 105 renk özneteliği çıkarmıştır. Farklı yöntemleri karşılaştırarak, test edilen derin öğrenme ağlarının (AlexNet, VGG16, ResNet34, EfficientNet-b0 ve MobileNetV2) metriklerini (doğruluk, kesinlik, hatırlama, F1 puanı) bulmuşlardır. Ölçülen makine

öğrenme algoritmalarından destek vektör makinesi (SVM), k-en yakın komşu (kNN) ve rastgele ormandan (RF) daha iyi olduğunu tespit etmişlerdir. Ayrıca, veri seti ve sınıflandırma görevimiz için test edilen ML/DL algoritmaları arasında ResNet34 ağına %99,7 doğruluk, %99,6 kesinlik, %99,7 hatırlama ve %99,7 F1 puanı ile en iyi sonuçları elde ettiğini bulmuşlardır (Tan, L., Lu, J., & Jiang, H.,2021).

Mokhtar ve ark., Sınıflandırma aşaması için farklı çekirdek fonksiyonlarına sahip Destek Vektör Makinesi (SVM) algoritması kullanılmaktadır. Hem eğitim hem de test aşamaları için toplam 800 sağlıklı ve enfekte domates yaprağı görüntüsü veri seti kullanılmıştır. Sunulan yaklaşımın performansını değerlendirmek için N-kat çapraz doğrulama tekniği kullanılır. Deneysel sonuçlar, önerilen sınıflandırma yaklaşımının doğrusal çekirdek fonksiyonunu kullanarak %99.83 sınıflandırma doğruluğu elde ettiğini göstermiştir (Mokhtar, U. ve ark.,2015).

Bakr ve ark., DenseNet201 adlı transfer öğrenme modeline dayalı bir CNN sınıflandırıcı önermiştir. Hangisinin bitki hastalıklarını en yüksek doğrulukla tespit edebileceğini görmek için dört derin öğrenme modelinin (VGG16, Inception V3, ResNet152V2 ve DenseNet201) analizi yapılmış. Kullanılan görüntü veri seti, domates için 9 hastalık ve bir sağlıklı sınıf, patates için 2 hastalık ve bir sağlıklı sınıf ve biber için 1 hastalık ve bir sağlıklı olmak üzere 15 farklı sınıfa ayrılmış 3 mahsul, domates, patates ve biberin 28310 yaprak fotoğrafını içermektedir. Deneysel sonuçlar önerilen modelin %99.44 ile en yüksek eğitim doğruluğuna ve %98.70 doğrulama doğruluğuna ulaştığını göstermektedir (Bakr ve ark., 2022).

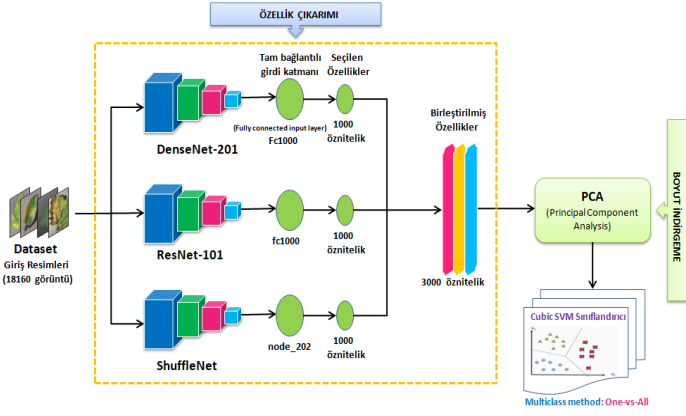
Too ve diğ., 38 sınıf ve 54.306 görüntüden oluşan veri seti üzerinde VGG16, Inception-v4, ResNet50, ResNet101, ResNet152 ve DenseNet121 CNN modellerini uygulamışlardır. %99,75 doğruluk oranını yakalamışlardır (Too, Yujian, Njuki, & Yingchun, 2019).

Sonuç olarak yapılan çalışmalar incelendiğinde bitki hastalıklarının tespitinde ve sınıflandırmasında Evrişimli Sinir Ağı (CNN) mimarileri kullanılarak yüksek doğruluk oranı elde edildiği görülmektedir.

3. Materyal ve Metot

Bu çalışmada Literatür taraması sonucunda yaygın olarak kullanılan CNN tabanlı AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet kullanılmıştır. Yapılan analizlerden sonra doğruluk oranı yüksek olan DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilmiştir. 24 bit derinliğe sahip görüntülerden özellik çıkarımı yapılmıştır. Elde edilen özelliklere PCA ile boyut indirgeme tekniği uygulanmıştır. Daha sonra makine öğrenmesi sınıflandırıcılarından Cubic SVM ve One-vs-All sınıflandırma yöntemiyle optimize edilerek domates yaprakları hastalıkları tespit edilmiştir.

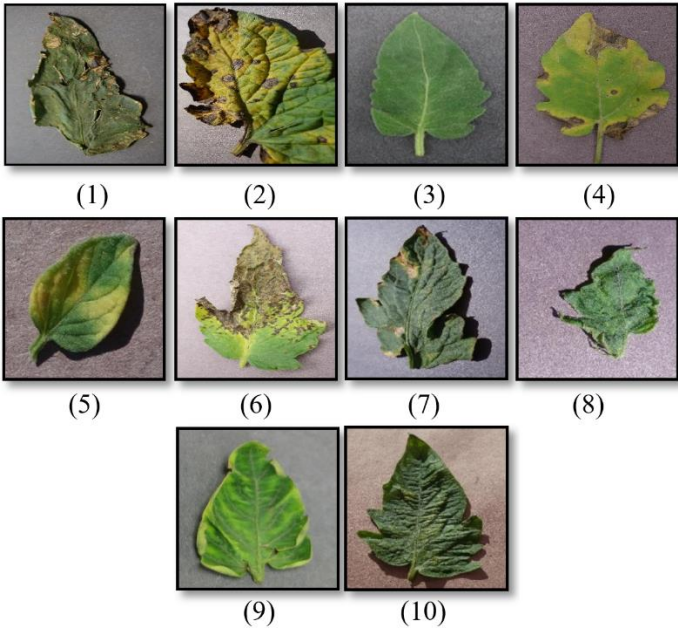
Bu bölümde çalışmada kullanılan veri seti, CNN mimarileri, PCA ve makine öğrenmesi sınıflandırmaları yöntemleri incelenmiştir. Bu çalışmada kullanılan yöntemin akış diyagramı Şekil 3'te verilmiştir.



Şekil 3. Önerilen yaklaşımda kullanılan yöntemin akış diyagramı

3.1. Veri Seti

Bu çalışmada 9 hastalıklı ve 1 sağlıklı sınıftan oluşan ve 18.160 domates yaprağı görüntüsü bulunan veri seti kullanılmıştır (Kaggle, 2021). Genel erişime açık Kaggle domates yaprağı hastalığı veri setinde bulunan görüntüler ve sınıflar Şekil 4'teki gibidir.



Şekil 4. Veri seti sınıfları ve örnek görüntüler (Kaggle, 2021)

Tablo 1. Veri Setindeki Sınıflara Ait Görüntü Sayısı ve Hastalık Tipi (Kaggle, 2021)

Hastalık Tipi	Sınıf	Görüntü Sayısı
Bakteri Lekesi	1	2127
Erken Yanıklık	2	1000
Sağlıklı	3	1591
Geç Yanıklık	4	1909
Yaprak Kalıbı	5	952
Septoria Yaprak Lekesi	6	1771
Hedef Nokta	7	1404
Mozaik Virüsü	8	373
Sarı Yaprak Kıvrılma Virüsü	9	5357
Örümcek Akarları	10	1676

Bu çalışmada kullanılan veri seti 18160 görüntü ve 9 hastalıklı ve 1 sağlıklı olmak üzere toplam 10 sınıftan oluşmaktadır. Veri seti 2127 tane bakteri lekeli, 1000 tane erken yanıklık, 1591 tane sağlıklı, 1909 tane geç yanıklık, 952 tane yaprak kalıbı, 1771 tane septoria yaprak lekeli, 1404 tane hedef nokta, 373 tane mozaik virüsü, 5357 tane sarı yaprak kıvrılma virüsü ve 1676 tane örümcek akarları yaprak görüntülerinden oluşmaktadır. Çalışmada kullanılan veri setinde bulunan sınıflara ait görüntü sayıları ve hastalık tipi Tablo 1'de verilmiştir.

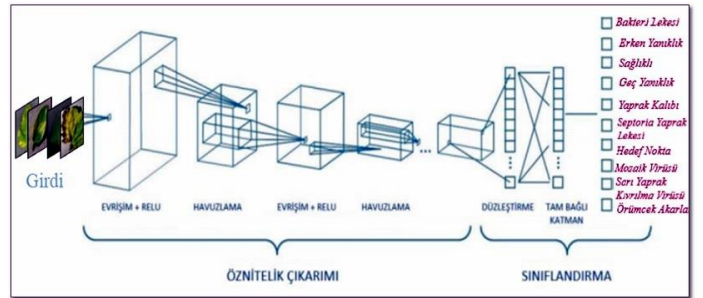
3.2. Öznitelik Çıkartma

Yapısal olmayan verilerde öznitelik çıkartma işlemi yapmak için bu verilerin matematiksel formda yapılara, yani nümerik değerlere dönüştürülmesi gerekmektedir. Özellik çıkartma işlemlerini gerçekleştirebilmek için öncelikle yapısal olmayan veriler algoritmalar tarafından anlaşılabilir temsillere dönüştürülür. Daha sonra özellik çıkartma işlemleri yapılır. Çeşitli metotlarla görsellerdeki özellikleri (features) çıkaran ve onları sınıflandıran CNN mimarileri farklı katmanlardan oluşmaktadır. Bu mimariler ile etkili ve verimli sonuçlar alınabilir. Çalışmada AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet mimarileri kullanılarak doğruluk oranları analiz edilmiştir. Yapılan analizlerden sonra doğruluk oranı yüksek olan DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilerek özellik çıkartma yapılmıştır. Şekil 3'te önerilen yaklaşımda kullanılan yöntemle özellik çıkartma gösterilmiştir.

3.2.1. Evrişimli Sinir Ağları (Convolutional Neural Network – CNN)

Evrişimli sinir ağları (CNN) çok katmanlı algılayıcıların bir türüdür. En etkili ve doğruluk oranı yüksek sonuçlar alındığı için özellikle görüntü işleme alanında daha çok kullanılmaktadır. (Tüfekçi & Karpat, 2019).

CNN mimarileri çok katmanlı bir yapıya sahiptir. Görüntüler üzerinde daha hızlı ve doğruluk oranı yüksek sonuçlarla sınıflandırma işlemi yapılmasını sağlamaktadır. CNN mimarilerinde bulunan temel katmanlar Giriş, Evrişim Katmanı, Havuzlama Katmanı ve Sınıflandırma (Tam bağlantılı katman) katmanlarıdır. CNN mimarisi ve katmanlar Şekil 5'te verilmiştir.



Şekil 5. CNN mimarisi ve katmanlar

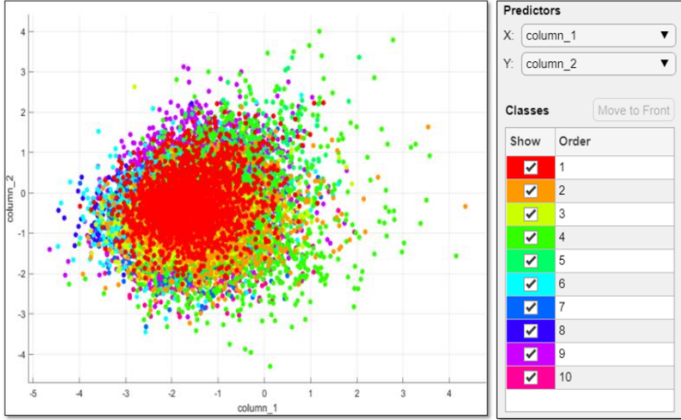
Bu çalışmada AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet ön eğitilmiş Evrişimli Sinir Ağı modelleri ile sınıflandırma çalışması yapılmıştır.

3.2.2. Mimari Birleştirme

Bu çalışmada CNN modellerinden DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri kullanılarak 18160 domates yaprağı görüntüsünden 3000 tane öznitelik çıkartılmıştır. Elde edilen öznitelikler MATLAB R2021b uygulamasında birleştirilip karma (hibrit) bir Evrişimli Sinir Ağı

modeli oluşturulmuştur. Şekil 3'te Evrişimli Sinir Ağı modelinin birleştirilmiş hali gösterilmektedir.

Şekil 6'da Mimariler birleştirildikten sonraki veri seti sınıf dağılımı ve sınıflar gösterilmiştir.



Şekil 6. Mimariler birleştirildikten sonraki veri seti sınıf dağılımı ve sınıflar

3.3. PCA Metodu ile Boyut İndirgeme

Jolliffe, PCA (Principal Component Analysis) verideki önemli örüntüleri ortaya çıkartan ve veriyi analiz etmek için kullanılan istatistiksel bir yöntemdir (Jolliffe, 2002).

Öksüz ve ark., PCA metodu büyük boyutlu bir veri setini daha düşük boyutlu bir veri seti haline getirir. Bu yöntemde en büyük özdeğere sahip olandan en düşük özdeğere sahip olana doğru sıralanır. İstenilen değişimi yakalayan sayıda özvektör seçildikten sonra bir doğrusal dönüşüm yapılır. (Öksüz ve ark., 2020).


Bu çalışmada, elde edilen hibrit CNN mimarisi ile öznelikleri çıkartılmış domates yaprağı görüntülerine PCA tekniği uygulanmıştır. 18160 görüntüden 3000 öznelikli çıkartılmış iken PCA yöntemi uygulandıktan sonra doğruluk oranı en yüksek sonuç alındığı gözlemlenen 1500 öznelikli boyutuna indirgenmiştir. Şekil 3'te DenseNet-201, ResNet-101 ve ShuffleNet modelleri birleştirildikten sonra PCA uygulanmış hali gösterilmektedir.

3.4. Destek Vektör Makineleri (SVMs)

Farklı çekirdek fonksiyonlarına sahip Destek Vektör Makineleri, verileri özellik alanına yansıtarak ve daha sonra optimal ayrı hiper-düzlemi bularak doğrusal olmayan bir problemi doğrusal olarak ayrılabilir bir soruna dönüştürebilir. Bu yöntem başlangıçta iki sınıf problemleri çözmek için önerilmiştir. Daha sonra, bu tekniği çok sınıflı sınıflandırma problemlerine genişletmek için birkaç stratejinin önerilmiştir (Vapnik, 1995).

Ön işleme ve özellik (öznelikli) çıkartma adımları bittikten sonra, el yazısı basamaklı görüntülerin sınıflandırılması SVM sınıflandırıcısı tarafından gerçekleştirilir. SVM sınıflandırıcısının eğitimi, matris formunda depolanan özellik vektörleri alınarak yapılmıştır. Sakının testi, eğitim sonucu kullanılarak yapılmıştır. Hibrit CNN SVM modelinde, otomatik olarak oluşturulan özellikler el yazısı basamak veri kümesini eğitmek ve test etmek için SVM modülüne aktarılır. MNIST'in test verileri benzer şekilde önceden işlenir ve daha sonra sınıflandırıcısı test etmek için kullanılır (Ahlawat & Choudhary, 2020).

Şekil 7'de SVM'nin asıl olarak ihtiyacı olan, pozitif örnekler sınıfını negatif örnekler sınıfından ayırt etmek için en büyük marjı olan hiper-düzlemi bulmak olduğu görülmektedir.



Şekil 7. SVM ile sınıflandırma

3.4.1. Cubic SVM

Sünnetci ve ark., 137 COVID-19, 90 normal ve 90 pnömoni kişilerden alınan görüntülerden oluşan veri seti üzerinde AlexNet CNN mimarisi kullanmışlardır. Her görüntü için 1000 özelliği çıkartılmıştır. Kübik destek vektör makinesi (Cubic Support Vector Machine, Cubic SVM) sınıflandırıcısı kullanılarak % 95.27 doğruluk elde etmişlerdir (Sünnetci ve ark., 2021).

Bu çalışmada domates yaprakları hastalıklarının tespiti ve sınıflandırılması için diğer sınıflandırıcı yöntemleri sonuçları gözlemlenmiş ve en başarılı doğruluk sonucu alınan Kübik Destek Vektör Makinesi (Cubic SVM) Sınıflandırıcısı ve One-vs-All multi-class metodu (tekniki) kullanılmıştır.

3.5. Model Performans Ölçüm Metrikleri

CNN mimarileri ile eğitilen veri setlerinin doğru sınıflandırma oranını hesaplamak için Hata (Karmaşıklık) matrisi kullanılır. Hata (karmaşıklık) matrisinde tahmin edilen ve gerçek değerlerin Gerçek pozitif (True Positive-TP), Yanlış pozitif (False Positive-FP), Yanlış negatif (False Negative -FN) ve Yanlış negatif (True Negative-TN) parametreleri verilir. Doğruluk, duyarlılık, kesinlik ve F-score bu parametrelerle elde edilir. Sınıflandırma doğruluk oranları Tablo 2'de gösterilen hata matrisinde belirtilen ölçümler ile hesaplanmaktadır.

Hata matrisi terimlerinin anlamları aşağıdaki gibidir:

- ✓ True Positive (TP): Pozitif sınıfa ait olan ve sınıflandırıcı tarafından doğru şekilde sınıflandırılan veri kümeleridir.
- ✓ True Negative (TN): Sınıflandırıcı tarafından doğru olarak sınıflandırılan negatif sınıfa ait veri kümesidir.
- ✓ False Positive (FP): Negatif sınıfa ait olduğu halde yanlış sınıflandırılır ve pozitif sınıf olarak tanımlanır.
- ✓ False Negative (FN): Gerçekte pozitif sınıfa ait olduğu halde negatif sınıf olarak tanımlanır.

Tablo 2. Hata (Karmaşıklık) matrisi

Hata Matrisi	Tahmin Edilen		
	1 (Positive)	0 (Negative)	
Gerçek	1	True Positive (TP)	False Positive (FP)
	0	False Negative (FN)	True Negative (TN)

Oluşturulan model üzerinde yapılan sınıflandırma performansını belirlemek için hata matrisi kullanılarak metrikler aşağıdaki denklemlerdeki gibi hesaplanır.

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

$$\text{Kesinlik (Pre)} = \frac{TP}{(TP+FP)} \quad (2)$$

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

$$F - \text{score} = 2 * \frac{(\text{kesinlik} * \text{duyarlılık})}{(\text{kesinlik} + \text{duyarlılık})} \quad (4)$$

Sınıflandırma problemleri için önemli olan diğer performans metriği de ROC eğrisidir. ROC eğrisinde hatasız olan incelemede eğri (0,0), (0,1) ve (1,1) noktalarından geçer. En hatalı olan ROC eğrisi (0,0) dan (1,1) noktalarından geçer. Bu iki eğriye göre değerlendirmeler yapılır (Hoo ve ark., 2017). TP değerinin FP değerine oranı ROC eğri grafiğini göstermektedir. ROC eğrisinin altında kalan alan (AUC) değerini verir. Bu değer 0'dan 1'e doğru yaklaşması pozitif değerlerin negatif değerlerden başarılı bir şekilde ayrıldığı anlamına gelir (Chaovalitwongse vd., 2007).

4. Deneysel Sonuçlar ve Tartışma

Bu çalışmada domates yaprağı hastalıklarının sınıflandırılması için Materyal ve Metot bölümünde belirtilen veri seti üzerinde DenseNet-201, ResNet-101 ve ShuffleNet ön eğitilmiş ağ mimarileri birleştirilerek uygulandıktan sonra PCA, Cubic SVM Cubic SVM sınıflandırıcı ve One-vs-All Çok Sınıflı bileşen yöntemleri uygulanmıştır. Bu çalışmada ayrıca Cross-Validation yöntemi ile 10 katlı bir çapraz doğrulama işlemi gerçekleştirilmiştir.

Öncelikle genel erişime açık Kaggle domates yaprağı görüntülerinden oluşan veri seti üzerinde AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet CNN mimarileri uygulanmıştır. Her bir model için 1000'er öznitelik elde edilmiştir. Tablo 3'te AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet CNN mimarileri sınıflandırma doğruluk oranları analiz edilmiştir. Her bir mimaride doğruluk oranı en yüksek sınıflandırıcının Cubic SVM olduğu gözlemlenmiştir.

Tablo 3. AlexNet, DenseNet-201, GoogleNet, MobileNet, ResNet-101 ve ShuffleNet CNN mimarileri sınıflandırma doğruluk oranları (%)

CNN Mimarileri	Cubic SVM
AlexNet	93.5
DenseNet-201	97.1
GoogleNet	91.0
MobileNet	94.5
ResNet-101	97.4
ShuffleNet	96.6


Daha sonra doğruluk oranı en yüksek DenseNet-201, ResNet-101 ve ShuffleNet CNN mimari modelleri birleştirilerek

uygulanmış ve bu mimarilerin 3000 öznitelik çıkarılmış ve veri seti oluşturulmuştur.

		Model 1									
True Class		Predicted Class									
		1	2	3	4	5	6	7	8	9	10
1		2117	1		2		2	1		3	1
2		7	938		14	2	5	27	1		6
3				1576				13		1	1
4		1	17	2	1878	4	2	4			1
5		3	2			929	5	2			11
6		4	6	1	1	3	1744	9	1		2
7		1	6		1		7	1367		1	21
8						3			368		2
9		4				1				5342	10
10					1			20			1655

Şekil 8. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin Karmaşıklık Matrisi

DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin Karmaşıklık Matrisi Şekil 8'deki gibidir. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin doğruluk oranı %98.6 bulunmuştur. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin ROC Eğrisi Şekil 9'daki gibidir.



Şekil 9. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin ROC Eğrisi

Oluşturulan veri setine PCA ile boyut indirilmesi yapılarak öznitelik sayısı 1500'e indirilmiştir. Yapılan analizlere göre mimariler üzerinde doğruluk oranı en yüksek çıkan Cubic SVM sınıflandırıcısı ve One-vs-All çok sınıflı bileşen metodu uygulanarak %99.2 doğruluk oranına ulaşılmıştır. Şekil 10'da DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin PCA ile boyut indirilmesi yapılarak, Cubic SVM sınıflandırıcı ve One-vs-All çok sınıflı bileşen metodu ile oluşan Karmaşıklık Matrisi gösterilmiştir. Önerilen yöntemin sınıflandırma performansını sınıf bazında değerlendirmek üzere metrikler üzerinden elde edilen deneysel sonuçlar Tablo 4'te verilmiştir.

True Class	1	2	3	4	5	6	7	8	9	10
1	2121	1		1			2		2	
2	5	954	1	17	3	4	12	1		3
3			1586				3		1	1
4		11	2	1890	2	1	2		1	
5		1			946	2	1		1	1
6	2	1			1	1762	4	1		
7	1	4	3			6	1372	2	1	15
8							1	372		
9									5353	4
10		1					9		1	1665

Şekil 10. DenseNet-201, ResNet-101 ve ShuffleNet birleştirilmiş CNN mimarisinin PCA ile boyut indirgenmiş halinin karmaşıklık matrisi

Şekil 11'de önerilen modelin gerçek pozitif (TPR-True Positive Rates) ve yanlış negatif oranlarının (FNR-False Negative Rates) karmaşıklık matrisi gösterilmiştir.

True Class	1	2	3	4	5	6	7	8	9	10	TPR	FNR
1	99.7%	0.0%		0.0%			0.1%		0.1%		99.7%	0.3%
2	0.5%	95.4%	0.1%	1.7%	0.3%	0.4%	1.2%	0.1%		0.3%	95.4%	4.6%
3			99.7%				0.2%		0.1%	0.1%	99.7%	0.3%
4		0.6%	0.1%	99.0%	0.1%	0.1%	0.1%		0.1%		99.0%	1.0%
5		0.1%			99.4%	0.2%	0.1%		0.1%	0.1%	99.4%	0.6%
6	0.1%	0.1%			0.1%	99.5%	0.2%	0.1%			99.5%	0.5%
7	0.1%	0.3%	0.2%			0.4%	97.7%	0.1%	0.1%	1.1%	97.7%	2.3%
8							0.3%	99.7%			99.7%	0.3%
9									99.9%	0.1%	99.9%	0.1%
10		0.1%					0.5%		0.1%	99.3%	99.3%	0.7%

Şekil 11. Önerilen modelin TPR ve FNR oranları

Şekil 12'de pozitif tahmin değerleri (Positive Predictive Values-PPV) ve yanlış keşif oranları (False Discovery Rates-FDR) gösterilmiştir.

True Class	1	2	3	4	5	6	7	8	9	10
1	99.6%	0.1%		0.1%			0.1%		0.0%	
2	0.2%	98.0%	0.1%	0.9%	0.3%	0.2%	0.9%	0.3%		0.2%
3			99.6%				0.2%		0.0%	0.1%
4		1.1%	0.1%	99.1%	0.2%	0.1%	0.1%		0.0%	
5		0.1%			99.4%	0.1%	0.1%		0.0%	0.1%
6	0.1%	0.1%			0.1%	99.3%	0.3%	0.3%		
7	0.0%	0.4%	0.2%			0.3%	97.6%	0.5%	0.0%	0.9%
8							0.1%	98.9%		
9									99.9%	0.2%
10		0.1%					0.6%		0.0%	98.6%

PPV	99.6%	98.0%	99.6%	99.1%	99.4%	99.3%	97.6%	98.9%	99.9%	98.6%
FDR	0.4%	2.0%	0.4%	0.9%	0.6%	0.7%	2.4%	1.1%	0.1%	1.4%

Şekil 12. Önerilen modelin PPV ve FDR oranları

Şekil 13'te önerilen yöntemin sınıflara göre ROC eğrileri gösterilmiştir. 3. Bölümde çalışmada kullanılan veri setindeki sınıf numaralarına karşılık gelen hastalık tipi Tablo 1'de verilmiştir.

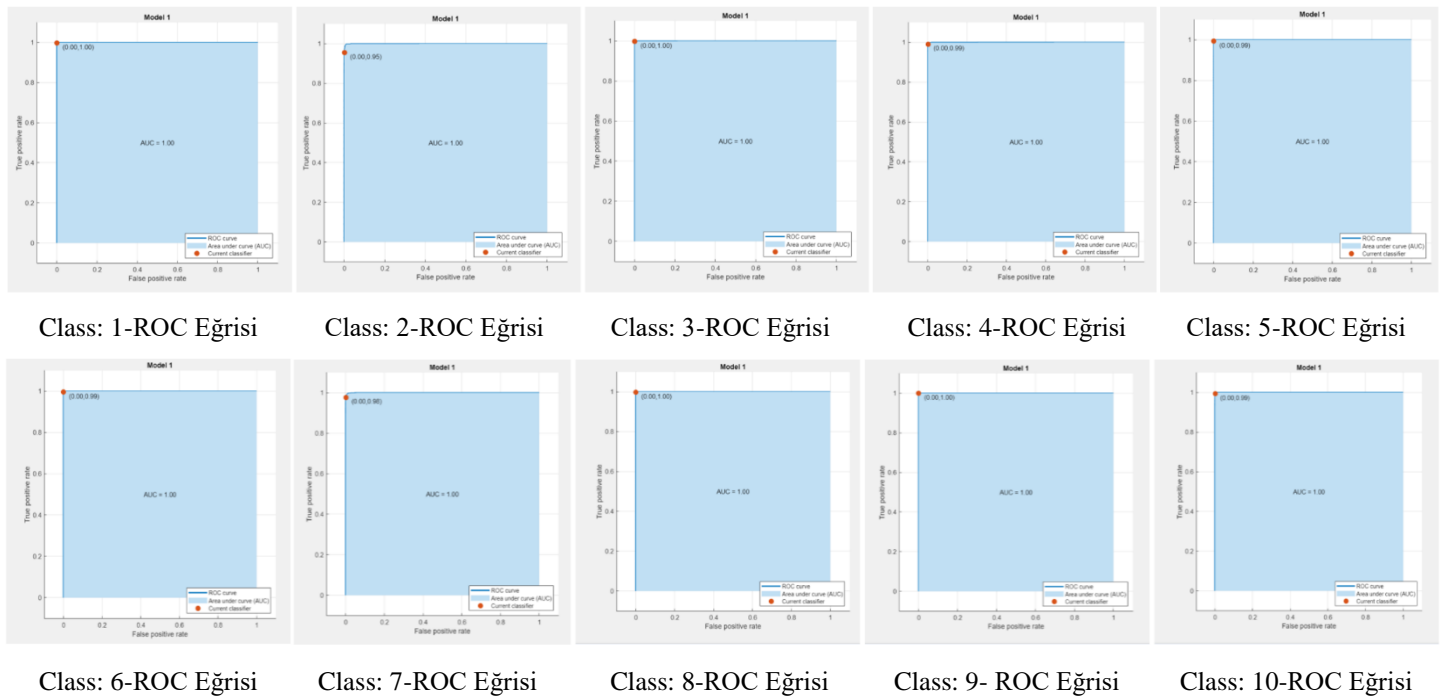
5. Sonuçlar

Bu çalışmada domates yaprağı hastalıklarının etkili bir şekilde tespit edilebilmesi için Cubic SVM algoritması ve One-vs-All çok sınıflı bileşen metodu kullanılarak sınıflandırma doğruluğunun artırılması amaçlanmıştır. Bu kapsamda CNN mimarisinden DenseNet-201+ ResNet-101+ ShuffleNet mimarileri kullanarak domates yaprağı görüntülerinden sınıflandırmada kullanılacak özellikler elde edilmiştir. Elde edilen bu özellikler PCA yöntemi ile boyut azaltma işlemi yapılarak en yüksek doğruluk oranı elde edilmiştir. Önerilen yöntemden önceki mimarilerde tek tek incelendiğinde doğruluk oranı bireysel olarak en yüksek %97,4 iken önerilen yöntemle doğruluk oranı %99,2 olmuştur.

Yapılan analizler sonucunda elde edilen deneysel sonuçlar, Cubic SVM sınıflandırıcısının doğru parametreler ve optimizasyon yardımıyla yüksek sınıflandırma doğruluğuna ulaştığı görülmektedir. Ayrıca boyut indirgeme metodu ile de maliyet ve zamandan tasarruf edildiği görülmüştür. Yapılan çalışmalar sonucunda sınıflandırma işleminin doğru parametreler yardımıyla yüksek doğruluk oranları elde edileceği gözlemlenmiştir. Ayrıca diğer sınıflandırıcılar gibi Cubic SVM sınıflandırıcısının da domates yaprağı hastalıklarının teşhisinde önemli ve etkili bir tespit yöntemi olduğu söylenebilir.

Tablo 4. Öznitelik çıkarım yöntemi ve sınıflandırıcıya göre doğruluk, kesinlik, duyarlılık ve F_1 (%) sonuçları

Yöntem	Öznitelik Sayısı	Sınıflandırıcı	Sınıf Adı	Acc	Pre	Rec	F_1
DenseNet-201, ResNet-101 ve ShuffleNet + PCA (Önerilen Yöntem)	1500	CSVM	<i>Bakteri Lekesi</i>	99,92	99,71	99,62	99,67
			<i>Erken Yanıklık</i>	99,64	95,40	98,04	96,70
			<i>Sağlıklı</i>	99,93	99,68	99,62	99,65
			<i>Geç Yanıklık</i>	99,79	99,00	99,05	99,03
			<i>Yaprak Kalıbı</i>	99,93	99,36	99,36	99,36
			<i>Septoria Yaprak Lekesi</i>	99,87	99,49	99,26	99,37
			<i>Hedef Nokta</i>	99,63	99,72	97,58	97,65
			<i>Mozaik Virüsü</i>	99,97	99,73	98,93	99,33
			<i>Sarı Yaprak Kıvrılma Virüsü</i>	99,93	99,92	99,86	99,89
			<i>Örümcek Akarları</i>	99,80	99,34	98,57	98,95
Ağırlıklı Ortalama				99,84	98,93	98,99	98,96



Şekil 13. Önerilen yöntemin sınıflara göre ROC eğrileri

Kaynakça

- Acikgoz, H. (2022). A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting. *Applied Energy*, (305). doi:https://doi.org/10.1016/j.apenergy.2021.117912.
- Agarwal, M., Singh, A., Arjaria, S., Sinha, A., & Gupta, S. (2020). ToLeD: Tomato leaf disease detection using convolution neural network. *Procedia Computer Science*, 167, 293-301.
- Ahlatwat, S., & Choudhary, A. (2020). Hybrid CNN-SVM classifier for handwritten digit recognition. *Procedia Computer Science*, 167, 2554-2560.
- Al-Amin, M., Karim, D. Z., & Bushra, T. A. (2019, December). Prediction of rice disease from leaves using deep convolution neural network towards a digital agricultural system. In 2019 22nd International Conference on Computer and Information Technology (ICCIT) (pp. 1-5). IEEE.
- Arivazhagan, S., Shebiah, R. N., Ananthi, S. N., & Varthini, S. V. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: The CIGR Journal*, 15, 211-217.
- Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., & Stefanovic, D. (2019). Solving Current Limitations of Deep Learning Based Approaches for Plant Disease Detection. *Symmetry*, 11(7). doi:10.3390/sym11070939
- Bakr, M., Abdel-Gaber, S., Nasr, M., & Hazman, M. (2022). DenseNet Based Model for Plant Diseases Diagnosis. *European Journal of Electrical Engineering and Computer Science*, 6(5), 1-9.
- Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299-315.
- Chaovallitwongse, W. A., Fan, Y. J., & Sachdeo, R. C. (2007). On the time series \$k\$-nearest neighbor classification of abnormal brain activity. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 37(6), 1005-1016.

- Cheng B. and Matson E. T., "A feature-based machine learning agent for automatic rice and weed discrimination," International Conference on Artificial Intelligence and Sof Computing, pp. 517– 527, 2015.
- Cheng, X., Zhang, Y., Chen, Y., Wu, Y., and Yue, Y., "Pest identification via deep residual learning in complex background," Computers and Electronics in Agriculture, vol. 141, pp. 351–356, 2017.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. doi:<https://doi.org/10.1016/j.compag.2018.01.009>
- GeethaRamani, R., & ArunPandian, J. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Comput. Electr. Eng.*, 76, 323-338.
- H. Sabrol, & K. Satish. (2016). Tomato plant disease classification in digital images using classification tree (pp. 1242–1246). Presented at the 2016 International Conference on Communication and Signal Processing (ICCSP). doi:10.1109/ICCSP.2016.7754351
- Hoo, Z. H., Candlish, J., & Teare, D. (2017). What is an ROC curve? *Emergency Medicine Journal*, 34(6), 357–359. doi:10.1136/emermed-2017-206735
- Jolliffe, I. T. (2002). *Principal component analysis for special types of data* (pp. 338-372). Springer New York.
- Kaggle. (2021, December 6). Kaggle. *Kaggle data set*. dataset. <https://www.kaggle.com/datasets>. Erişim: 18.10.2022
- Liu, Y., Tang, F., Zhou, D., Meng, Y., & Dong, W. (2016). Flower classification via convolutional neural network. In *2016 IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA)* (pp. 110–116). doi:10.1109/FSPMA.2016.7818296
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7.
- Mokhtar, U. *et al.* (2015). SVM-Based Detection of Tomato Leaves Diseases. In: *, et al. Intelligent Systems'2014. Advances in Intelligent Systems and Computing*, vol 323. Springer, Cham. https://doi.org/10.1007/978-3-319-11310-4_55
- Öksüz, C., & Güllü, M. K. (2020, October). Deep Feature Extraction Based Fine-Tuning. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Sannakki, S., Rajpurohit, V. S., Sumira, F., & Venkatesh, H. (2013). A neural network approach for disease forecasting in grapes using weather parameters. In *2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)* (pp. 1–5). doi:10.1109/ICCCNT.2013.6726613
- Shruthi, U., Nagaveni, V., & Raghavendra, B. K. (2019, March). A review on machine learning classification techniques for plant disease detection. In *2019 5th International conference on advanced computing & communication systems (ICACCS)* (pp. 281-284). IEEE.
- Sibiya, M., & Sumbwanyambe, M. (2019). A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. *AgriEngineering*, 1(1), 119-131.
- Song, K., Sun, X. Y., & Ji, J. W. (2007). Corn leaf disease recognition based on support vector machine method. *Transactions of the CSAE*, 23(1), 155-157.
- Suryawati, E., Sustika, R., Yuwana, R. S., Subekti, A., & Pardede, H. F. (2018, October). Deep structured convolutional neural network for tomato diseases detection. In *2018 international conference on advanced computer science and information systems (ICACSIS)* (pp. 385-390). IEEE.
- Sünneci, K. M. , Alkan, A. & Tar, E. (2021). Göğüs X-Ray görüntülerinin AlexNet tabanlı sınıflandırılması . *Computer Science , 5th International Artificial Intelligence and Data Processing symposium*, 375-384. DOI: 10.53070/bbd.989192
- Tan, L., Lu, J., & Jiang, H. (2021). Tomato Leaf Diseases Classification Based on Leaf Images: A Comparison between Classical Machine Learning and Deep Learning Methods. *AgriEngineering*, 3(3), 542–558. <https://doi.org/10.3390/agriengineering3030035>
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Comput. Electron. Agric.*, 161, 272–279.
- Tüfekçi, M., & Karpat, F. (2019). Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetinin Arttırılmasına Yönelik Yapılan Çalışmaların İncelenmesi. In *International Conference on Human-Computer Interaction, Optimization and Robotic Applications* (pp. 28-31).
- Vapnik, V. N. (1995). The nature of statistical learning. *Theory*.
- Walliser, J. (2018). *How to identify and control tomato plant disease*. <https://savvygardening.com/tomato-plant-disease/>