



Ön-Eğitilmiş CNN Mimarilerinin Füzyonu ile Mısır Yaprağı Hastalıklarının Sınıflandırılması

Ahmet Ciran¹, Erdal Özbay^{2*}

¹ Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-0280-5542), aciran@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.1216356)

ATIF/REFERENCE: Ciran, A. & Özbay, E. (2022). Ön-Eğitilmiş CNN Mimarilerinin Füzyonu ile Mısır Yaprağı Hastalıklarının Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 74-83.

Öz

Mısır, dünyanın birçok yerinde temel gıda olarak kullanılmaktadır. Mısır, yağ ve yüksek fruktozlu mısır şurubu yapmak için kullanılabilecek iyi bir nişasta kaynağıdır. Mısır ve mısır unu çok hayati ürünler olduğundan, Yanık, Pas ve Gri Yaprak Lekesi gibi bazı hastalıkların erken teşhisiyle bitkilerin iyileştirilmesini sağlanarak ürün kalitesinin düşmesi önlenilebilecektir. Bu sayede hem ürünün kalitesi hem de elde edilen ürün miktarı artırılabilir. Bu çalışmada, Evrişimli Sinir Ağı (CNN) tabanlı VGG-19, DenseNet-201 ve NasNet-Large modelleri kullanılarak mısır yaprağı görüntülerinden öznetelik çıkarımı yapılmıştır. Veri setindeki dengesizliğin giderilmesi için Sentetik Azınlık Yüksek Örneklemme Tekniği (SMOTE) yöntemi ile balans ayarı yapılmıştır. Öznetelik sayısını düşürmek için boyut indirgeme yöntemlerinden Temel Bileşen Analizi (PCA) kullanılmıştır. Mısır yaprağındaki hastalıkları sınıflandırmak amacıyla Destek-Vektör Makinaları (SVMs) algoritması kullanılmıştır. Algoritmanın performansını artırmaya yönelik GridSearchCV yaklaşımı ile mısır yapraklarındaki hastalıkları tanımlamak için Kernel function ve Box constrain hiperparametreleri optimize edilmiştir. Elde edilen deneysel sonuçlar genel erişime açık Kaggle mısır veya mısır yaprağı hastalığı veri kümesi üzerinde test edilmiştir. Elde edilen deneysel sonuçlarda sadece CNN ile özellik çıkarımı yapılan görüntülerin LibSVM ile sınıflandırılmasında 4 sınıf için sırasıyla %94,5, %94,4, %94,3, ve %96,2 doğruluk oranlarına ve %94,3 ağırlıklı ortalamaya ulaşılmıştır. Önerilen yöntem kullanılarak LibSVM ile 4 sınıf için sırasıyla %96,7, %96,7, %96,7 ve %97,8 doğruluk oranlarına ve %96,7 ağırlık ortalamaya ulaşılmıştır. Böylece önerilen yöntemle elde edilen sınıflandırma doğruluğunda optimizasyon yapılmadan elde edilen sınıflandırma doğruluğuna göre birinci sınıf için %2,2, ikinci sınıf için %2,3, üçüncü sınıf için %2,4 ve dördüncü sınıf için %1,6, bununla birlikte ağırlıklı ortalamada %2,4 oranında iyileşme sağlandığı görülmüştür.

Anahtar Kelimeler: CNN, LibSVM, Mısır yaprağı, Optimizasyon, PCA, Sınıflandırma.

Classification of Maize Leaf Diseases by Fusion of Pre-Trained CNN Architectures

Abstract

Maize is used as a staple food in many parts of the world. Maize is a good source of starch that can be used to make oil and high fructose corn syrup. Since maize and maize flour are very vital products, early diagnosis of some diseases such as Blight, Rust, and Gray Leaf Spot can prevent the deterioration of product quality by improving the plants. In this way, both the quality of the product and the amount of product obtained can be increased. In this study, feature extraction was performed from corn leaf images using Convolutional Neural Network (CNN) based VGG-19, DenseNet-201, and NasNet-Large models. In order to eliminate the imbalance in the data set, the balance was adjusted with the Synthetic Minority Over-Sampling Technique (SMOTE) method. Principal Component Analysis (PCA), one of the dimension reduction methods, was used to reduce the number of features. Support-Vector Machines (SVMs) algorithm was used to classify diseases in maize leaves. With the GridSearchCV approach to improving the

* Sorumlu Yazar: erdalozbay@firat.edu.tr

performance of the algorithm, the Kernel function and Box constrain hyperparameters have been optimized to identify diseases in corn leaves. The experimental results obtained were tested on the publicly accessible Kaggle corn or maize leaf disease dataset. In the experimental results obtained, 94.5%, 94.4%, 94.3%, and 96.2% accuracy rates and a weighted average of 94.3% were achieved for the 4 classes, respectively, in the classification of the images with only CNN and feature extraction with LibSVM. Using the proposed method, 96.7%, 96.7%, 96.7%, and 97.8% accuracy rates and 96.7% weight average were achieved for 4 classes with LibSVM, respectively. Thus, according to the classification accuracy obtained without optimization in the classification accuracy obtained with the proposed method, it was observed that there was an improvement of 2.2% for the first class, 2.3% for the second class, 2.4% for the third class, and 1.6% for the fourth class, and 2.4% in the weighted average.

Keywords: CNN, LibSVM, Maize leaf, Optimization, PCA, Classification.

1. Giriş

Son yıllarda mısır, modern dünyanın gıda ürünü ve çok çeşitli şekillerde kullanılabilen en önemli tahıl ürünü haline gelmiştir. İnsan beslenmesinde buğday ve pirinçten sonra en çok kullanılan bitkilerden biridir. Mısır, dört ay gibi bir sürede 2,5-4,5 metreye kadar büyüebilmekte ve bitki başına 600-1000 tohum verebilmektedir (Kırtok, 1998).

Mısır bitkisi tahıl ve otsu gövde olmak üzere iki şekilde kullanılabilir. Tahıl olarak doğrudan insan beslenmesinde (ekmek ve atıştırılabilir olarak) kullanılmaktadır, ancak aynı zamanda yemeklik yağ, nişasta, glikoz ve yem sektörlerinde de kullanılabilir. Otsu vücut ise hayvan besini olarak kullanılmaktadır (Şahin, 2001).

Tarım ürünlerindeki genel mahsul, dünya nüfusu arttıkça önem kazanmıştır. Bu nedenle, en önemli araştırma alanlarından biri, bütün bitkileri etkileyen bitki hastalıklarının belirlenmesidir. Bitki hastalıkları, tarımsal verimliliği ve kaliteyi etkileyen faktörlerden biridir (Weizheng, 2008). Hem verim hem de kalite kaybına neden olan bu hastalıklar önlenmediği takdirde tüm ürünler bundan etkilenmektedir. Bitkilerdeki hastalıkların tespiti için belirli peryotlarla bitki yapraklarının gözlemlenmesi gerekmektedir.

Mısırdaki gri yaprak lekesi, *Cercospora zeae-maydis* mantarının neden olduğu bir mısır hastalığıdır. Şu anda dünya çapında mısırın en önemli verim sınırlayıcı hastalıklarından biri olarak görülmekte ve doğu Amerika Birleşik Devletleri'nin birçok bölgesinde ve daha yakın zamanda ABD Mısır Kemer ve Afrika'nın geniş alanlarında mısır üretimi için ciddi bir tehdit oluşturmaktadır. Tipik olarak, semptomları alt yapraklarda görülmektedir (Ward, 1999). Şekil 1'de gri yaprak lekesi hastalığına sahip bir mısır yaprağı örneği gösterilmektedir.



Şekil 1. Gri yaprak lekeli mısır yaprağı

Düşük sıcaklıklar (16-23 °C) ve yüksek bağıl nem (%100), mısırdaki patojen *Puccinia sorghi*'nin neden olduğu yaygın pas mısır hastalıklarını desteklemektedir (Campus, 2012). Lezyonlar fonksiyonel yaprak alanını ve fotosentezi azaltmaktadır. Bu hastalığa bağlı olarak yaprakların hem üst hem de alt tarafında lekeler oluşmaktadır (Dillard & Seem, 1990). Şekil 2'de yaygın

pas lekeli hastalığına sahip bir mısır yaprağı örneği gösterilmektedir.



Şekil 2. Yaygın pas lekeli mısır yaprağı

Mısır yaprağı yanıklığı, *Exserohilum turcicum* mantarının neden olduğu bir mısır hastalığıdır. Bu hastalık düşük ila orta sıcaklıklarda ve yüksek bağıl nemde gelişmektedir. Semptomlar, yapraklar üzerinde oldukça büyük, gri, puro şeklinde lezyonların gelişmesi ile karakterize edilmektedir (Sibiya & Sumbwanyambe, 2019). Şekil 3'te yanık hastalığına sahip bir mısır yaprağı örneği gösterilmektedir.



Şekil 3. Yanık hastalıklı mısır yaprağı

Bu araştırma, biyolojik önemi büyük olan mısır hastalıklarını yapay zekâ yöntemlerinden biri olan derin öğrenme ile tespit etmeyi amaçlamaktadır. Bu konuda, literatürde yapılmış birçok çalışma bulunmaktadır.

Mevcut çalışmalardan yapılmış deneylerden birinde çeşitli görüntü işleme tekniklerini kullanarak mısır hastalığını tespit etmek için bir sistem oluşturulmuştur. RGB yaklaşımı yaprak görüntülerindeki renkleri tanımlamak için kullanılmış ve çeşitli özellik çıkarma yaklaşımları uygulanmıştır. Bu çalışmada destek vektör makineleri, karar ağaçları, rastgele orman ve naive bayes sınıflandırıcıları kullanılmıştır. Uygulanan birçok sınıflandırıcı ile RGB'yi tanımlamada başarılı sonuçlar elde edilmiştir (Kusumo vd., 2018).

Başka bir çalışma, genetik algoritmalar kullanan destek vektör makinalarının, mısır hastalığı sınıflandırmasında destek vektör makinalarından daha iyi sonuçlar üretilebileceği gösterilmiştir (Zhang vd., 2015).

Bhange vd., meyvelerin fotoğraflarını bir sisteme yükleyerek çiftçilerin meyve hastalıklarını tanımlamasına yardımcı olmak adına web tabanlı bir teknik önermişlerdir. Bu algoritma, nar tohumlarından önceden öğrenilmiş bir veri kümesini kullanmıştır. Kullanıcılar analiz etmek üzere sisteme çeşitli fotoğraflar aktarma yoluyla katkı sağlamıştır ve bu fotoğraflar, eğitim veri setindeki görüntülerle karşılaştırılarak hastalık şiddetini belirlemek için birkaç işlem adımından geçmiştir. Önerilen yaklaşımın deneysel sonuçlarında %82 doğruluk değerine ulaşılmıştır (Bhange & Hingoliwala, 2015).

Pujari vd. tarafından destek vektör makinaları (SVM'ler) ve YSA'ları karşılaştıran bir çalışma yürütülmüştür (Pujari vd., 2016). Buğday hastalıklarının yaprak görüntüleme ve veri işleme teknikleri kullanılarak tanımlanması, son zamanlarda çiftçiler tarafından büyük tarlaları izlemek için yaygın olarak kullanılmaktadır. SVM'ler, buğdaydaki hastalıkları tespit etmek ve sınıflandırmak için Dixit ve Nema gibi araştırmacılar tarafından kullanılmıştır. Araştırmada buğday yapraklarının SVM tanımlamasının önündeki temel endişeleri ve engelleri ayrıntılı olarak tartışmışlardır (Dixit & Nema, 2018).

2. İlgili Çalışmalar

Mısır yaprağı hastalığının anında ve kesin teşhisi için çok sayıda çalışma ortaya konmuştur. Araştırmacılar, farklı semptomlara sahip çeşitli bitki hastalıklarının hızlı tespiti için birçok yöntemi test etseler de, deneyimsiz çiftçiler için teşhis etmek profesyonel bitki patoloğlarına göre çok kolay değildir (Miller vd., 2009). Bitkilerin hastalık teşhisi ile tecrübesiz çiftçilere yardımcı olunabilmesi bakımından bitkilerin görsel görünümü ile farklı hastalıkları otomatik tespit etmek oldukça önemlidir.

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). Bu SVM tabanlı sınıflandırma yöntemi, en iyi doğruluğu sağlamasa da küçük veri kümeleri ve büyük veri kümeleri için faydalıdır.

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).

Kapon, mısır yaprağı hastalıklarıyla ilgili yaptığı çalışmada CNN mimarilerinden EfficientNet'i kullanmıştır. Önerilen yöntemde dört sınıf için sırasıyla %91,30, %97,71, %93,10 ve %100 doğruluk oranı elde etmiştir (Kapon, 2022).

Whxna, yaptığı çalışmalarda CNN mimarilerinden SqueezeNet'i ve optimize edici olarak Adam yöntemini kullanmıştır (Whxna, 2022).

Rage, mısır yaprağı hastalıklarıyla ilgili yaptığı çalışmada CNN mimarilerinden VGG16'yı ve optimize edici olarak Adam yöntemini kullanmıştır. Önerilen yöntemde mısır yaprakları için elde edilen doğruluk oranı %90,82'dir (Rage, 2022).

Panigrahi vd., düzeltilmiş doğrusal birim aktivasyon fonksiyonu ve bir Adam optimize edicisi ile parametreler değiştirilerek, geliştirilmiş CNN modeli ile ortalama % 98.78'lik doğruluk oranına ulaşmışlardır. (Panigrahi vd., 2020).

Olasılıksal sinir ağı (PNN) ve görüntü işleme yaklaşımı kullanılarak mısır yaprağı hastalıklarının tanımlanması için Chen ve Wang tarafından bir yöntem önerilmiştir (Chen vd., 2011). Bu yöntemler kullanılarak %90,4 doğruluk elde edilmektedir. Burada PNN sınıflandırıcısının dezavantajı, eğitim örneklerindeki artış nedeniyle hem doğruluk hem de yöntem hızının azalmasıdır. Xu vd., yedi tip mısır yaprağı üzerinde denenen adaptif ağırlıklandırma çoklu sınıflandırıcı füzyonuna dayalı mısır yaprağı hastalığı tespiti için bir yöntem önermişlerdir (Xu vd., 2015). Ortalama tanıma oranında %94,71'e ulaşılmıştır. Wang vd., Qi vd. ve Zhang mısır yapraklarının hastalıklarını tanımlamak için çeşitli görüntü işleme yöntemleri ve kombinasyon özellikleri önermişlerdir (Wang vd., 2009, Qi vd., 2016, Zhang vd., 2013). Bu çalışmalar maksimum %95,3 tanıma doğruluğuna sahiptir. Önerilen bu model, en iyi tanıma doğruluğu için mevcut talepleri karşılayamamaktadır. Derin öğrenme, son yıllarda mükemmel ilerlemeler sağlamıştır (Krizhevsky vd., 2017). Daha büyük boyutlu giriş görüntüsünden kullanışlı özellik gösterimi çıkarma yeteneğine sahiptir. Ayrıca, tarım alanında doğruluğun iyileştirilmesine ve bilgisayarlı görme kapsamının genişletilmesine yardımcı olan, mahsul hastalıklarının doğru bir şekilde tanımlanması için dedektörlere yardımcı olmaktadır.

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. Lu vd., 10 çeşit pirinç hastalığının tespiti için farklı algoritmalar, havuzlama işlemleri ve filtre boyutları kullanmış ve burada %95,48 doğruluk elde eden CNN tabanlı bir model önermiştir (Lu vd., 2017).

DeChant vd., mısırın kuzey yaprak yanıklığı hastalığının tespiti için CNN modelini kullanmış ve %96,7 doğruluk elde etmiştir (DeChant vd., 2017). Bu yöntemler, daha uzun yakınsama süresi ve daha fazla parametre ile daha iyi doğruluk sağlamasına rağmen, tanımlama oranına zarar vermektedir.

Sonuç olarak literatürde yapılmış mevcut çalışmalardan da anlaşılacağı üzere çalışmada ele alınan konu birçok araştırmacı tarafından üzerinde çalışılan popüler ve aktif bir çalışma alanıdır.

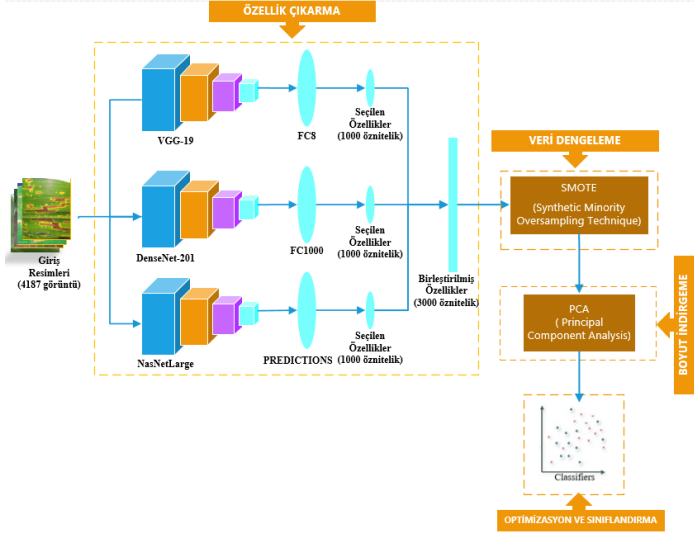
3. Materyal ve Metot

Bu çalışmada literatürde yaygın olarak kullanılan CNN tabanlı VGG-19, DenseNet-201 ve NasNet-Large modeller hibrit bir şekilde kullanılarak 24 bitlik görüntülerden özellik çıkarımı yapılmıştır. Elde edilen özelliklere, SMOTE işlemi yapılarak veri setinde balans ayarı yapılmış ve PCA ile boyut indirgeme tekniği uygulanmıştır. Daha sonra makina öğrenmesi sınıflandırıcılarından LibSVM modeli GridSearchCV yöntemiyle optimize edilerek mısır yaprakları hastalıkları tespit edilmiştir.

Makine öğrenmesi teknikleri ile yapılan sınıflandırmaların testlerle etkinliğinin tespit edilmesi önemlidir. Bu bakımdan doğruluk belirlenirken oluşturulan modelin performansı da dikkate alınmaktadır. Bu performansı belirlemek için bir karmaşıklık matrisi kullanılmıştır. Bu matris daha sonra doğruluk, kesinlik, duyarlılık ve F-ölçütü endekslerini

hesaplamak için kullanılmıştır. Bu sayede mısır yaprağı hastalıklarının belirlenmesi için bir yol haritası oluşturulmuştur.

Bu bölümde çalışmada kullanılan veri seti, CNN mimarileri, PCA, makine öğrenmesi sınıflandırmaları ve optimizasyon yöntemleri incelenmiştir. Makalede önerilen yöntemin akış diyagramı Şekil 4'te verilmiştir.



Şekil 4. Önerilen yöntemin akış diyagramı

3.1. Veri Seti

Çalışmanın veri seti kamuya açık bir veri kümesidir (Ghose, 2022). İlişkili veri setinde toplamda 4187 adet görüntü kullanılmıştır. Bu görüntülerin 1306 tanesi yaygın pas hastalığı olan görüntüler, 574 tanesi gri yaprak lekesi hastalığı olan görüntüler, 1145 tanesi yanık hastalığı olan görüntüler ve 1162 tanesi sağlıklı mısır yaprağı olan görüntülerdir. Veri setinde kullanılan görüntüler 24-bit ve renkli görüntülerdir.

3.2. Özellik Çıkarımı


Yeni bir CNN mimarisi tasarlamak, büyük miktarda veri ve kaynak gerektirdiğinden zaman alıcı bir süreçtir. Bununla birlikte ön-egitilmiş CNN mimarilerinin etkili bir şekilde kullanılmasıyla verimli sonuçlar elde etmek mümkündür. AlexNet, ResNet-101, DarkNet-53, VGG-19, DenseNet-201 ve NasNet-Large gibi önceden eğitilmiş modeller transfer öğrenimi için kullanılabilir.

Bu çalışmada transfer öğrenimi için ImageNet veri setinden ağırlıklar kullanılarak, önceden eğitilmiş VGG-19, DenseNet-201 ve NasNet-Large modelleri ile özellik çıkarımları yapılmıştır. Şekil 4'te önerilen yöntemle özellik çıkarımı gösterilmiştir.

3.2.1. Evrişimli Sinir Ağı (CNN)

Yapay zekânın bir dalı olan derin öğrenme, günümüzde son derece önemlidir. Ancak teknoloji ve veriler geliştikçe 2010'ların başında yeniden ortaya çıkmaya başlamıştır (Floridi, 2020). Son derece güçlü performans sonuçları üreten CNN modeli, bu ilginin ana itici güçlerinden birisidir. CNN yapısı, çağrışımları kullanan çok katmanlı bir YSA olarak düşünülebilir, en az bir katman matematiksel bir işlemi temsil etmektedir. Evrişimli katmanlara ek olarak, doğrusal olmayan katmanlar, havuz katmanları, düzgülleştirme katmanları ve YSA ile aynı işlevselliğe sahip tam bağlantılı katman bulunmaktadır (Albawi ve diğ., 2017).

Çok katmanlı yapısı, CNN'nin görüntüleri tek yapılı yapay sinir ağlarından daha hızlı ve daha iyi sonuçlarla sınıflandırmasını sağlamaktadır. CNN modelleri, evrişim katmanları, havuz katmanları, etkinleştirme işlevi katmanları ve tam bağlantılı katmanlar olmak üzere dört ana katmandan oluşmaktadır. Şekil 5'te tipik bir CNN mimarisi gösterilmektedir.




Şekil 5. CNN mimarisi

3.2.1.1. VGG-19 Modeli

VGG-19, 224×224 görüntü giriş boyutunu almaktadır. VGG'nin evrişimli katmanları, minimum alıcı bir alandan, yani 3×3'ten en küçük boyuttan yararlanmaktadır. Bunu bir ReLU aktivasyon fonksiyonu izlemektedir. ReLU, düzeltilmiş doğrusal birim aktivasyon fonksiyonu anlamına gelmektedir. ReLU'nun girişin pozitif olması için parça parça doğru bir fonksiyon olması demektir. Aksi halde girişin negatif olması çıkışın sıfır olması demektir. Evrişimden sonra uzamsal çözünürlüğün korunmasını sağlamak için sonraki adım 1 pikselde sabitlenmektedir (Geekycodesco, 2022).

VGG-19, tam bağlantılı üç katmana sahiptir. Üç katmanın ilk ikisinde her biri 4096 düğüm bulunmaktadır ve üçüncü katmanda 1000 düğüm bulunmaktadır. Bu, imagenet veri kümesinin sahip olduğu toplam sınıf sayısıdır (Geekycodesco, 2022). Şekil 6'da VGG-19 mimarisinin yapısı gösterilmiştir.

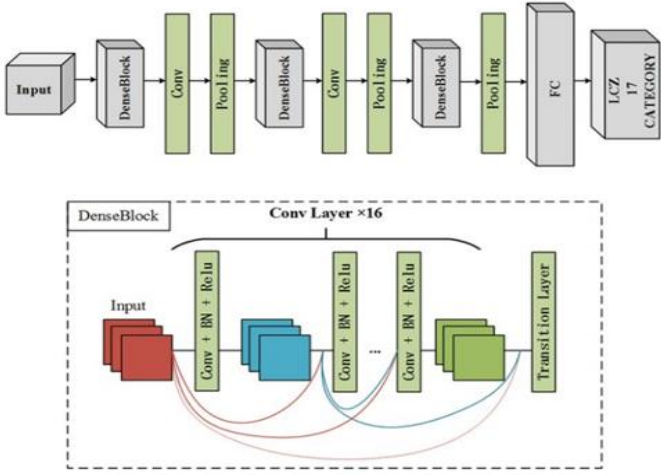


Şekil 6. VGG-19 mimarisi

Bu çalışmada CNN mimarisinde ön eğitimli VGG-19 modeli kullanılarak toplamda 4187 görüntüden 1000 öznelikli bir çıktı elde edilmiştir.

3.2.1.2. DenseNet-201 Modeli

DenseNet (Huang vd., 2017), verimli ve derin bir model oluşturmak için tüm katmanları bütünleştirmektedir. ResNet'e çok benzer, ancak bazı önemli farklılıkları bulunmaktadır. DenseNet, her katmanın bir sonraki katmanı beslemesi bakımından ResNet'e benzer bir modeldir. Bu ileri beslemeli bağlantılar sayesinde katman sayısı L'den L(L + 1)/2'ye artmaktadır (Miglanı & Bhatia, 2020). Her katmanın girişi, önceki tüm seviyeler için özellik haritalarını içermektedir. DenseNet, kaybolan gradyanları çözme yeteneği gibi birçok avantaja sahiptir (Lumini & Nanni, 2019). Şekil 7, DenseNet-201 mimarisini göstermektedir.

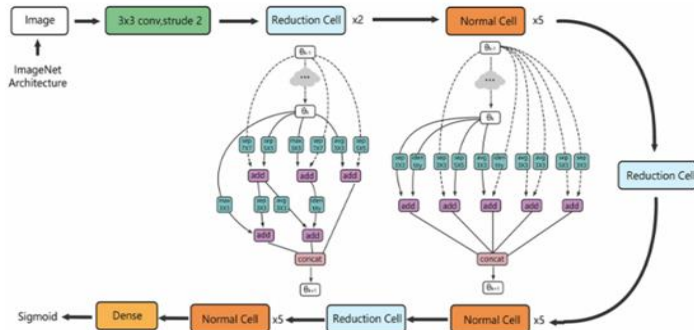


Şekil 7. DenseNet-201 mimarisi

Bu çalışmada CNN mimarisinde ön eğitilmiş DenseNet-201 modeli kullanılarak toplamda 4187 görüntüden 1000 öznitelikli bir çıktı elde edilmiştir.

3.2.1.3. NasNet-Large Modeli

Görüntü sınıflandırması için önemli bir ağ mimarisi oluşturmuşlardır. Küçük bir veri kümesinde mimari ağ blokları bulmayı ve ardından blokları daha büyük bir veri kümesine taşımayı önermişlerdir. Bu teknolojinin ana katkısı, NASNet arama kapsamı olarak bilinen yeni bir arama kapsamının oluşturulmasıdır. En uygun evrişim katmanını ("hücre") küçük bir veri kümesinde bulabilir ve daha büyük bir veri kümesine uygulayabilirsiniz. Bu ağ bileşenlerini daha fazla istifleyerek ağ, daha karmaşık ve daha büyük veri kümelerini işleyebilir. Bu ağ evrişim tasarımı NASNet mimarisi olarak adlandırılmıştır (Zoph vd., 2018). Şekil 8, NasNet-Large mimarisini göstermektedir.



Şekil 8. NasNet-Large mimarisi

Bu çalışmada CNN mimarisinde ön eğitilmiş nasnetlarge modeli kullanılarak toplamda 4187 görüntüden 1000 öznitelikli bir çıktı elde edilmiştir.

3.2.2. Mimari Birleştirme

Bu araştırmada CNN modellerinden VGG-19, DenseNet-201 ve NasNet-Large mimarileri kullanılarak 4187 görüntüden öznitelikler çıkarılmıştır. Daha sonra MATLAB 2021b ortamı ile elde edilen öznitelikler birleştirilip hibrit bir model oluşturulmuştur. Bu model tarafından yapılan öznitelik çıkarılması sonucunda 4187 görüntüden 3000 öznitelik bulunmuştur. Şekil 4'te modellerin birleştirilmiş hali gösterilmektedir.

3.3. Veri Dengeleme

e-ISSN: 2148-2683

Sınıflandırma veya tahmine dayalı modellemede yüksek model doğruluğu sağlamak için modele sağlanan verilerin kalitesi iyileştirilmelidir. Birçok veri ön işleme tekniği, aykırı değerlerin kaldırılması, yinelenen değer işleme, normalleştirme, eksik değerler vb. gibi sorunları ele alır, ancak gözden kaçan önemli bir konu, dengesiz sınıf dağılımlarının düşük doğruluk oranlarına yol açabilmesidir (Arık, 2021). Şekil 4' te veri dengeleme mimarisi gösterilmiştir. Bu çalışmada verilerin dengesiz sınıf dağılımı problemini ortadan kaldırmak için sentetik azınlık aşırı örnekleme (SMOTE) yöntemi kullanılmıştır.

3.3.1. SMOTE (Synthetic Minority Over-Sampling Technique)

SMOTE, sentetik veriler üreten bir aşırı örnekleme işlemidir. Bu, veri bilimi projelerinde en sık kullanılan yöntemlerden biridir. Bu yöntem, veri sayısı az olan sınıfının örnekleri arasında belirli işlemleri gerçekleştirerek sınıfının yeni bir örneğini oluşturmaktadır. Sentetik örnekler oluşturma basamakları şu şekildedir: Öncelikle incelenen öznitelik vektörü (E_i) ile en yakın komşusu arasındaki farkı alınır, sonra bu farkı 0 ile 1 arasında rastgele bir sayı δ ile çarpılır ve çıkan sonuç incelenen özellik vektörüne eklenir ve yeni örnekler oluşturulmaktadır (Muratlar, 2021). Sentetik örnek hesaplaması Denklem 1' deki gibi formüle edilmektedir:


$$E_{yeni} = E_i + (E_i - E_j)\delta \quad (1)$$

3.4. PCA Boyut İndirgeme

Algoritmalar, veri kümesinin tüm niteliklerini modele sığdırmaya çalıştıklarından dolayı yanlış tahminlere yol açabilmektedir. Bu sorunu çözmek ve büyük veri kümelerinin aşırı uyum ve karmaşıklığını önlemek için veri boyutunu azaltma teknikleri geliştirilmiştir (Mosetti, 2016).


Bu çalışmada boyut indirgeme yöntemlerinden PCA kullanılmıştır. PCA, değişken kombinasyonlarının temel veri türü özelliklerini tanımlayan istatistiksel bir yaklaşımdır (Ali vd., 2022).

PCA, özellik çıkarma ve boyut küçültme açısından iyi bir performans sergilemektedir. Veri seti, değişken sayısı ve gözlem sayısını içeren bir matris ile belirtilir ve matris, tek değerli ayrıştırma kullanılarak yeni bir matrise yorumlanmadan önce birim varyans ve sıfır anlamlılık ile normalleştirilmektedir (Ali vd., 2022).



Şekil 9. PCA uygulanmadan önceki 3 boyutlu veri seti

Şekil 9'da PCA uygulanmadan önceki 3 boyutlu veri seti gösterilmiştir. Şekil 10'da PCA uygulandıktan sonraki 2 boyutlu veri seti gösterilmektedir.



Şekil 10. PCA uygulandıktan sonraki 2 boyutlu veri seti

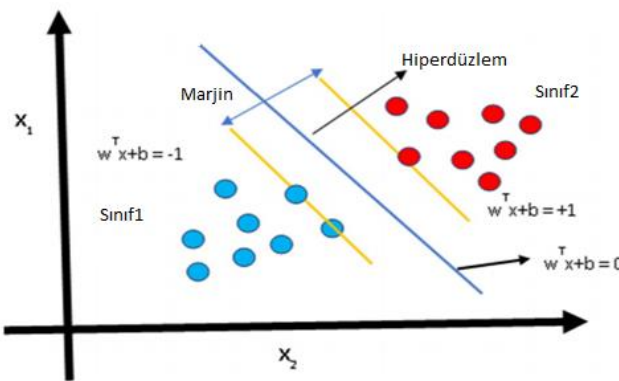
3.4.1. PCA Uygulanmış Veri Seti

Bu çalışmada, CNN ile öznetelikleri çıkartılmış mısır yaprağı görüntülerine PCA uygulanmıştır. CNN ile 4187 görüntüden 3000 öznetelik çıkartılmış iken PCA yöntemi uygulandıktan sonra öz netelik sayısı 191'e düşürülmüştür. Şekil 4'te VGG-19, DenseNet-201 ve NasNet-Large modelleri birleştirildikten sonra PCA uygulanmış hali gösterilmektedir.

3.5. Destek Vektör Makinaları (SVMs)

SVMs, 1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından istatistiksel öğrenme teorisine dayalı olarak geliştirilen denetimli bir makine öğrenme algoritmasıdır (Akpinar, 2014). Çekirdek işlevli SVM, doğrusal olmayan ayrılabilir veriler için mükemmel bir çözüm sunmaktadır (Metlek & Kayaalp, 2020).

İstatistiksel öğrenme teorisine dayanan SVMs, olası makine öğrenme tekniklerinden birisidir. SVMs hem doğrusal hem de doğrusal olmayan verileri işleyebilen bir sınıflandırma sistemidir. Verileri iki gruba ayırın ve yüksek boyutlarda doğrusal bir optimal ayırma hiperdüzlemi oluşturmak için destek vektörlerini ve kenarları (veya sınıfları) kullanmaktadır. Uygun bir doğrusal olmayan eşleme kullanarak orijinal eğitim verilerini daha yüksek boyutlara dönüştürmektedir. Bir hiperdüzlem ile verileri iki sınıfa ayırabilmektedir (Atallah & Al-Mousa, 2019).



Şekil 11. SVMs ile sınıflandırma örneği

Şekil 11'de görülebileceği gibi, SVM'nin temel gereksinimi, pozitif örnekler kümesini negatif örnekler kümesinden ayırt etmek için en büyük marjı olan hiperdüzlemi bulmaktır. Destek

vektör makinelerini kullanarak $f(x) = b + wx$ tipi doğrusal sınıflandırma gerçekleştirilmektedir. En büyük kenarı ve türünün doğrusal sınıflandırmasını kullanarak optimal hiperdüzlemi hesaplamak için bir destek vektör makinesi kullanılmaktadır. $f(x) = b + wx$ burada w ağırlık vektörünü, x eğitim örneklerini ve b bias'ı temsil etmektedir.

3.5.1. LibSVM

LibSVM, SVM'de kullanılan bir kütüphanedir. Amacı, SVM'yi kullanışlı bir araç olarak tanıtmaktır. Epsilon SVM regresyonunu, nu-SVM regresyonunu, tek sınıf SVM'yi, C-SVM sınıflandırmasını ve nu-SVM sınıflandırmasını birleştirmektedir. Ayrıca, otomatik model seçimi için bir C-SVM sınıflandırma aracı sağlamaktadır. En son sürümü Ağustos 2022'de yayınlanan 3.3'tür (Fan & Lin, 2005).

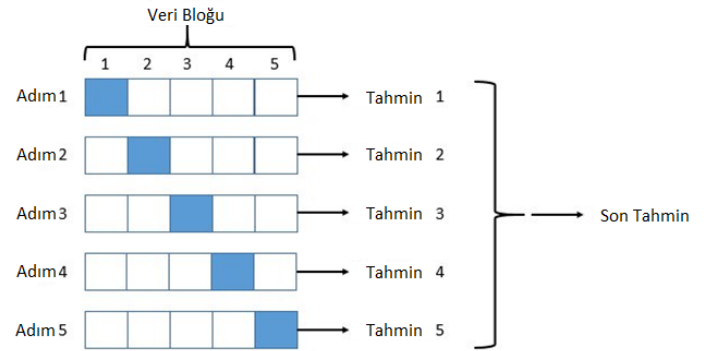
Bu çalışmada mısır yaprakları hastalıklarının sınıflandırılması için LibSVM kullanılmıştır.

3.6. Optimizasyon Yöntemi

Bu çalışmada Weka programında, GridSearchCV hiperparametre optimizasyon yöntemi ile LibSVM algoritmasının performansı artırılmıştır.

3.6.1. GridSearchCV Hiper-parametre Optimizasyonu

GridSearchCV, tahmin edici parametrelerini değiştirmek için Scikit öğrenme çerçevesi tarafından sağlanan bir sınıftır. Tipik olarak, önce aranacak bir parametre sözlüğü oluşturmakta, ardından GridSearchCV en uygun parametreleri sağlamak için gerekli model değişikliklerini yapmaktadır (Huang vd., July 2004).



Şekil 12. 5 katmanlı GridSearchCV örneği

Şekil 12'de görüldüğü gibi çapraz doğrulama sırasında veriler birkaç parçaya bölünebilmektedir. Örneğin, 5 bileşene bölünen verilerin beşte birini dışarıda bırakarak modele beş kez sığdırılmaktadır. Bu eksik veriler performansı değerlendirmek için kullanılmaktadır.

3.7. Model Performans Değerlendirme Metrikleri

Seçilen parametrelerin sınıflandırma doğruluğu üzerindeki etkisini görmek için önce farklı hiperparametrelerle deneyler yapılmış ve sonuçları bildirilmiştir. Sonuçları karşılaştırmak ve daha iyi kararlar almak için model değerlendirme metriklerinden doğruluk ölçüleri kullanılmıştır. Doğruluk, beklenen sınıf ile gerçek sınıfın uyumunu oransal olarak veren bir ölçümdür. Örneğin doğruluk, model tarafından mısır hastalığı riski altında olduğu tahmin edilen vakaların sayısı ile gerçek risk altındaki tüm vakaların sayısı ile model tarafından risksiz olarak tahmin edilen vakaların gerçek risk altındaki vakalara oranı olarak ifade edilmektedir. Sınıflandırma doğruluk değerleri Tablo 1'de

gösterilen karmaşıklık matrisinde belirtilen metriklerden elde edilmektedir.

Tablo 1. İki sınıflı karmaşıklık matrisi

		Tahmin Edilen Sınıf	
		Risk Var	Risk Yok
Gerçek Sınıf	Risk Var	TP (True Positive)	FP (False Pozitive)
	Risk Yok	FN (False Negative)	TN (True Negative)

Karmaşıklık matrisi terimleri ve anlamları aşağıda listelenmiştir.

- True pozitive (TP): pozitif sınıfa ait olan ve sınıflandırıcı tarafından doğru şekilde sınıflandırılan veri kümelerini temsil etmektedir.
- True Negative (TN): Sınıflandırıcı tarafından doğru olarak sınıflandırılan negatif sınıfa ait veri kümesini temsil etmektedir.
- False pozitive (FP): Uygulamada, negatif sınıfa ait ifadeler yanlış sınıflandırılır ve pozitif sınıf olarak tanımlanır.
- False Negative (FN): Aslında pozitif sınıfa ait olan bir taksonomik terim, negatif sınıf olarak tanımlanır.

Sınıflandırma performansını belirlemek için karmaşıklık matrisi kullanılarak belirlenen metrikler, açıklamalarıyla birlikte aşağıda listelenmiştir:

Doğruluk: Önerilen modelin başarısının değerlendirilmesi için kullanılmaktadır. Modeldeki doğru tahminler kümesinin tüm veri kümesine bölünmesiyle bir doğruluk değeri hesaplanmaktadır (Öğündür, 2019). Performans değerlendirme metrikleri kullanılarak Denklem 2’de verildiği gibi hesaplanmaktadır.

$$Doğruluk (Acc) = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2)$$

Kesinlik: Özellikle yanlış pozitif tahminlerin maliyeti yüksek olduğunda önemlidir. Örneğin model, e-posta kutunuza gelmesi gereken bir maili spam (FP) olarak işaretlerse, almanız gereken önemli maili göremezsiniz ve kayıp bir durumda olursunuz. Kesinlik, bir model seçerken önemli bir kriterdir (Öğündür, 2019). Denklem 3’te verildiği şekilde hesaplanmaktadır.

$$Kesinlik (Pre) = \frac{TP}{(TP+FP)} \quad (3)$$

Duyarlılık: Yanlış negatifleri tahmin etmenin maliyetinin yüksek olduğu durumlarda da yararlı bir ölçümdür. Mümkün olduğunca yüksek olmalıdır. Örneğin oluşturduğumuz bir dolandırıcılık tespit modeli, hileli bir işlemi hileli değil olarak işaretliyorsa böyle bir durumun sonuçları bankalar için sorun teşkil etmektedir (Öğündür, 2019). Denklem 4’te gösterildiği şekilde hesaplanmaktadır.

$$Duyarlılık (Rec) = \frac{TP}{(TP+FN)} \quad (4)$$

F-ölçütü: Bu değer hassaslık ve duyarlılık (geri çağırma) değerlerinin harmonik ortalamasını vermektedir (Öğündür, 2019). Denklem 5’te verildiği gibi hesaplanmaktadır.

$$F - ölçütü = 2 * \frac{(kesinlik * duyarlılık)}{(kesinlik + duyarlılık)} \quad (5)$$

AUC: ROC eğrisi sınıflandırma problemleri için önemli bir diğer performans ölçümüdür. ROC bir olasılık eğrisidir ve altında kalan alan olarak adlandırılan AUC değeri ayrılabilirliğin derecesini veya ölçüsünü temsil etmektedir. AUC [0, 1] aralığında değerler üretmektedir. AUC değerinin 1’e yaklaşmasıyla sınıflandırıcının daha doğru bir tahmin yaptığı söylenebilir. 0,5 değeri ise sınıflandırıcının rastgele tahminler yaptığını göstermektedir. Bu değer altındaki değerler için sınıflandırıcının iyi performans göstermediği vurgulanmaktadır (Kılıç, 2013).

Ağırlıklı Ortalama: Ağırlıklı ortalama F1 puanı, her sınıfın desteğini hesaba katarken, sınıf başına tüm F1 puanlarının ortalaması alınarak belirlenmektedir (Leung, 2021).

4. Araştırma Sonuçları ve Tartışma

Bu çalışmada mısır yaprağı hastalıklarının tespiti için öncelikle 3. bölümde açıklanan veri setinin üzerine yine 3. bölümde yer alan CNN mimarilerinden VGG-19, DenseNet-201, NasNet-Large modelleri uygulandıktan sonra SMOTE, PCA, LibSVM ve GridSearchCV yöntemleri uygulanmıştır. Çalışmada Cross-Validation yöntemi ile 10 katlı bir çapraz doğrulama işlemi gerçekleştirilmiştir.

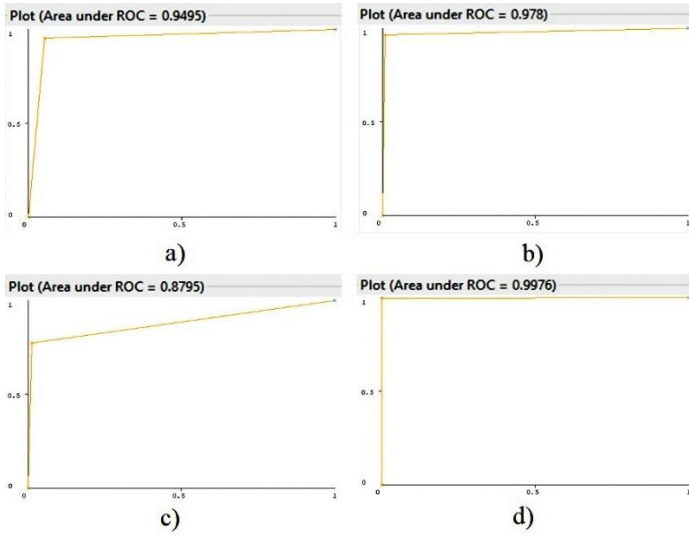
İlk olarak mısır yaprağı görüntülerinden öznetelik çıkarımı yapmak için CNN mimarilerinden sırasıyla VGG-19, DenseNet-201 ve NasNet-Large modelleri kullanılmıştır. Yapılan deney sonucunda herbir model için 1000’er öznetelik elde edilmiştir. Daha sonra kullanılan bu üç model birleştirilerek 3000 öznetelikli veri seti oluşturulmuştur. Oluşturulan veri setine WEKA 3.8.6 programı ile LibSVM sınıflandırıcısı uygulanmış ve %94,3 oranında doğruluk elde edilmiştir. Ayrıca Tablo 2’de karmaşıklık matrisi görülmektedir. Şekil 13’te ise sınıfların ROC eğrileri gösterilmiştir.

Tablo 2. VGG-19, DenseNet-201 ve Nasnet-Large modelleri birleştirilerek öznetelik çıkarılmış görüntülere LibSVM uygulandıktan sonraki karmaşıklık matrisi

VGG-19, DenseNet-201 ve NasNet-Large		Blight	Common Rust	Gray Leaf Spot	Healthy
True Class	Blight	1091	8	43	3
	Common Rust	45	1259	2	
	Gray Leaf Spot	116	14	442	1
	Healthy	3	1		1158
		Predicted Class			

Tablo 6. Öznitelik çıkarım yöntemi ve sınıflandırıcıya göre kesinlik, duyarlılık, F-1 ölçütü ve ROC sonuçları

Öznitelik Çıkarım Yöntemi	Öznitelik Sayısı	Sınıflandırıcı	Sınıf Adı	Pre	Rec	F ₁	ROC
VGG-19 + DenseNet-201 + NasNet-Large	3000	LibSVM	Blight	%86,9	%95,3	%90,9	%94,9
			Common Rust	%98,2	%96,4	%97,3	%97,8
			Gray Leaf Spot	%90,8	%77,1	%83,4	%87,9
			Healthy	%99,7	%99,7	%99,7	%99,7
			Ağırlıklı Ortalama	%94,5	%94,4	%94,3	%96,2
VGG-19 + DenseNet-201 + NasNet-Large + SMOTE + PCA + Optimizasyon (Önerilen Yöntem)	191	LibSVM	Blight	%92,5	%94,4	%93,4	%96
			Common Rust	%99	%95,6	%97,3	%97,6
			Gray Leaf Spot	%95,5	%97	%96,2	%97,8
			Healthy	%99,5	%99,7	%99,6	%99,8
			Ağırlıklı Ortalama	%96,7	%96,7	%96,7	%97,8



Şekil 13. (a) Blight hastalığı için ROC eğrisi (b) Common Rust hastalığı için ROC eğrisi (c) Gray Leaf Spot hastalığı için ROC eğrisi (d) Healthy için ROC eğrisi


Oluşturulan veri setine, dengesiz sınıf dağılımlarını önlemek için WEKA 3.8.6 programı ile SMOTE sentetik veri üretme yöntemi uygulanarak balans ayarı yapılmıştır. Bu çalışma sonucunda sınıflarda sırasıyla 1145, 1306, 1146 ve 1162 toplamda 4759 veri elde edilmiştir. Böylece veri setinde bulunan 4187 adet veri SMOTE işleminden sonra 4759'a yükseltilmiştir.

Tablo 3. VGG-19, DenseNet-201 ve Nasnet-Large modelleri ile öznitelik çıkarılmış görüntülere SMOTE, PCA, LibSVM ve GridSearch uygulandıktan sonraki karmaşıklık matrisi

VGG-19, DenseNet-201 ve NasNet-Large + SMOTE+PCA+ OPTİMİZASYON		Blight	Common Rust	Gray Leaf Spot	Healthy
True Class	Blight	1081	11	48	5
	Common Rust	52	1248	5	1
	Gray Leaf Spot	34		1112	
	Healthy	2	1		1159
		Predicted Class			

Ardından önerilen yaklaşımda WEKA 3.8.6 programı ile PCA yöntemi kullanılarak bileşen azaltma kriteri olarak açıklanan varyansı belirtme seçeneği aktif edilmiş ve açıklanan varyans oranı %90 olarak belirlenmiştir. Yapılan deneyler sonucunda PCA uygulanmadan önce 3000 öznitelige sahip veri seti PCA uygulandıktan sonra 191 öznitelige sahip olmuştur.

Son olarak 191 öznitelige sahip 4759 veriye GridSearchCV optimizasyon yönteminde Xproperty cost ve Yproperty gamma olarak seçilip LibSVM sınıflandırıcısı uygulanmış ve %96,7 doğruluk oranı elde edilmiştir. Ayrıca Tablo 3'te karmaşıklık matrisi görülmektedir. Şekil 14'te ise sınıfların ROC eğrileri gösterilmiştir.



Şekil 14. (a) Blight hastalığı için ROC eğrisi (b) Common Rust hastalığı için ROC eğrisi (c) Gray Leaf Spot hastalığı için ROC eğrisi (d) Healthy için ROC eğrisi

Mısır yaprağı hastalıklarının teşhisi için hiper-parametre optimizasyonu yapılmamış ve önerilen yöntem ile LibSVM algoritması kullanılarak yapılan sınıflandırmanın ortalama performans sonuçları Tablo 6'da karşılaştırılmıştır.

Bu çalışmada çoklu sınıflar ile çalışıldığı için her sınıfın ayrı ayrı F-ölçütü değeri hesaplanmış ve bu değerlerin ağırlıklı ortalaması alınmıştır. Çalışmada optimizasyon yapılmayan LibSVM ile mısır yaprağı hastalığı teşhisinde %94,3 ağırlıklı ortalama bulunurken, optimizasyon yapılan LibSVM ile mısır yaprağı hastalığının teşhisinde %96,7 ağırlıklı ortalama elde edilmiştir.

5. Sonuçlar

Bu çalışmada mısır yaprağı hastalıklarının etkili bir şekilde teşhis edilebilmesi için optimize edilmiş LibSVM algoritması kullanılarak sınıflandırma doğruluğunun artırılması amaçlanmıştır. Bu kapsamda CNN mimarisinden VGG-19 +DenseNet-201+ Nasnet-Large modelleri kullanılarak mısır yaprağı görüntülerinden sınıflandırmada kullanılacak öz nitelikler elde edilmiştir. Elde edilen bu öz nitelikler SMOTE, PCA ve GridsearchCV yöntemleri ile veri dengeleme, boyut azaltma ve optimizasyon yapılarak en yüksek doğruluk oranı elde edilmiştir. Önerilen yöntemden önceki doğruluk oranı %94,3 iken önerilen yöntemle bu oran %96,7 doğruluk oranı elde edilmiştir.

Yapılan testler sonucunda elde edilen deneysel sonuçlar, LibSVM sınıflandırıcısının dengeli veri, doğru parametreler ve optimizasyon yardımıyla yüksek sınıflandırma doğruluğuna ulaştığını göstermektedir. Ayrıca boyut indirgeme metodu ile de maliyet ve zamandan tasarruf edildiği görülmüştür. LibSVM sınıflandırıcısının performansının artırılmasında özellikle GridSearchCV yönteminin kullanımının sınıflandırma doğruluğunu artırdığı vurgulanmıştır. Yapılan çalışmalar neticesinde LibSVM sınıflandırıcısının düşük verimlilik probleminin doğru parametreler yardımıyla çözülebildiği görülmüştür. Ayrıca diğer sınıflandırıcılar gibi LibSVM sınıflandırıcısının da mısır yaprağı hastalıklarının teşhisinde önemli bir teşhis yöntemi olduğu ifade edilebilmektedir.

Kaynakça

- Akpınar, H. (2014). Data: Veri Madenciliği Veri Analizi, 1. baskı. Papatya Yayıncılık Eğitim, İstanbul.
- 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.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET) (pp. 1-6). Ieee.
- Ali, H., Maulud, A. S., Zabiri, H., Nawaz, M., Suleman, H., & Taqvi, S. A. A. (2022). Multiscale Principal Component Analysis-Signed Directed Graph Based Process Monitoring and Fault Diagnosis. ACS omega, 7(11), 9496-9512.
- Arık, A. O. (2021, Jan 14). Medium: <https://okanarik.medium.com/smote-synthetic-minority-oversampling-technique-c52d4fbec47e>. Erişim: 04.10.2022
- Atallah, R., & Al-Mousa, A. (2019, October). Heart disease detection using machine learning majority voting ensemble method. In 2019 2nd international conference on new trends in computing sciences (ictcs) (pp. 1-6). IEEE.
- Bhange, M., & Hingoliwala, H. A. (2015). Smart farming: Pomegranate disease detection using image processing. Procedia computer science, 58, 280-288.
- Campus, P. (2012). Inoculation methods and disease rating scales for maize diseases. (Revised). Directorate of Maize Research, New Delhi.
- Chen, L., & Wang, L. Y. (2011). Research on application of probability neural network in maize leaf disease identification. J. Agricult. Mech. Res, 33(6), 145-148.
- DeChant, C., Wiesner-Hanks, T., Chen, S., Stewart, E. L., Yosinski, J., Gore, M. A., ... & Lipson, H. (2017).

- Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning. Phytopathology, 107(11), 1426-1432.
- Dillard, H. R., & Seem, R. C. (1990). Incidence-severity relationships for common maize rust on sweet corn. Phytopathology, 80(9), 842-849.
- Dixit, A., & Nema, S. (2018). Wheat leaf disease detection using machine learning method-a review. Int. J. Comput. Sci. Mob. Comput, 7(5), 124-129.
- Fan, P. H. C. R. E., & Lin, C. J. (2005). Dimensionality Reduction via Sparse Support Vector Machines. Journal of Machine Learning Research, 6, 1889-1918.
- Floridi, L. (2020). AI and its new winter: From myths to realities. Philosophy & Technology, 33(1), 1-3.
- Geekycodesco. (2022, Mart 13). By geekycodesco: <https://geekycodes.in/what-is-the-vgg-19-neural-network/> Erişim: 28.09.2022
- Ghose, S. (2022). Kaggle. Kaggle: <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset>. Erişim: 17.09.2022
- Hao, W., & Zhang, Z. (2019). Spatiotemporal distilled dense-connectivity network for video action recognition. Pattern Recognition, 92, 13-24.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2004, July). Extreme learning machine: a new learning scheme of feedforward neural networks. In 2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541) (Vol. 2, pp. 985-990). Ieee.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition; 2017. Honolulu, HI.[Google Scholar].
- Kapon, O. (2022, February). Kaggle: <https://www.kaggle.com/code/omreekapon/corn-and-maize-diseases-classification/notebook>. Erişim: 04.10.2022
- Kılıç, S. (2013). Klinik karar vermede ROC analizi. Journal of Mood Disorders, 3(3), 135-40.
- Kırtok, Y. (1998). Mısır: üretimi ve kullanımı. Kocaoluk Yayınevi.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90.
- Kusumo, B. S., Heryana, A., Mahendra, O., & Pardede, H. F. (2018, November). Machine learning-based for automatic detection of corn-plant diseases using image processing. In 2018 International conference on computer, control, informatics and its applications (IC3INA) (pp. 93-97). IEEE.
- Leung, K. (2021, Jan 4). Towards Data Science: <https://towardsdatascience.com/micro-macro-weighted-averages-of-f1-score-clearly-explained-b603420b292f>. Erişim: 03.10.2022
- Li, C., & Lanying, W. (2011). Research on Application of Probability Neural Network in Maize Leaf Disease Identification [J]. J Agric Mechan Res, 6.
- Lu, Y., Yi, S., Zeng, N., Liu, Y., & Zhang, Y. (2017). Identification of rice diseases using deep convolutional neural networks. Neurocomputing, 267, 378-384.
- Lumini, A., & Nanni, L. (2019). Deep learning and transfer learning features for plankton classification. Ecological informatics, 51, 33-43.

- Metlek, S., & Kayaalp, K. (2020). Makine Öğrenmesinde, Teoriden Örnek MATLAB Uygulamalarına Kadar Destek Vektör Makineleri. İksad Yayınevi.
- Miglani, V., & Bhatia, M. P. S. (2020, February). Skin lesion classification: A transfer learning approach using efficientnets. In International Conference on Advanced Machine Learning Technologies and Applications (pp. 315-324). Springer, Singapore.
- Miller, S. A., Beed, F. D., & Harmon, C. L. (2009). Plant disease diagnostic capabilities and networks. Annual review of phytopathology, 47(1), 15-38.
- Mosetti, R. (2016). Principal Component Analysis of quantum correlation. The European Physical Journal Plus, 131(12), 1-8.
- Muratlar, E. R. (2021, Temmuz 9). Dengesiz Veri Setlerinde Modelleme. Veri Bilimi: [https://www.veribilimiokulu.com/dengesiz-veri-setlerinde-modelleme/#:~:text=SMOTE\(Synthetic%20Minority%20Over%2DSampling,yeni%20az%C4%B1n%C4%B1k%20s%C4%B1n%C4%B1f%C4%B1%20C3%B6rneklere%20yaratmakt%C4%B1r](https://www.veribilimiokulu.com/dengesiz-veri-setlerinde-modelleme/#:~:text=SMOTE(Synthetic%20Minority%20Over%2DSampling,yeni%20az%C4%B1n%C4%B1k%20s%C4%B1n%C4%B1f%C4%B1%20C3%B6rneklere%20yaratmakt%C4%B1r.). Erişim: 05.10.2022
- Öğündür, G. (2019, Nov 9). Medium: <https://medium.com/@gulcanogundur/do%C4%9Fruluk-accuracy-kesinlik-precision-duyarl%C4%B1%C4%B1k-recall-ya-da-f1-score-300c925feb38>. Erişim: 02.10.2022
- Panigrahi, K. P., Sahoo, A. K., & Das, H. (2020, June). A cnn approach for corn leaves disease detection to support digital agricultural system. In 2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184) (pp. 678-683). IEEE.
- Pujari, D., Yakkundimath, R., & Byadgi, A. S. (2016). SVM and ANN based classification of plant diseases using feature reduction technique. IJIMAI, 3(7), 6-14.
- Qi, Z., Jiang, Z., Yang, C., Liu, L., & Rao, Y. (2016). Identification of maize leaf diseases based on image technology. Journal of Anhui Agricultural University, 43(2), 325-330.
- Rage, S. (2022). Kaggle: <https://www.kaggle.com/code/sailikhitara/maize-mutant-classification-using-vgg16/notebook>. Erişim: 04.10.2022
- 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.
- Şahin, S. (2001). Türkiyede Mısır Ekim Alanlarının Dağılışı Ve Mısır Üretimi. Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi, 21(1).
- Wang, N., Wang, K., Xie, R., Lai, J., Ming, B., & Li, S. (2009). Maize leaf disease identification based on fisher discrimination analysis. Scientia Agricultura Sinica, 42(11), 3836-3842.
- Ward, J. M., Stromberg, E. L., Nowell, D. C., & Nutter Jr, F. W. (1999). Gray leaf spot: a disease of global importance in maize production. Plant disease, 83(10), 884-895.
- Weizheng, S., Yachun, W., Zhanliang, C., & Hongda, W. (2008, December). Grading method of leaf spot disease based on image processing. In 2008 international conference on computer science and software engineering (Vol. 6, pp. 491-494). IEEE.
- Whxna. (2022, August). Kaggle: <https://www.kaggle.com/code/jiaowoguanren/corn-or-maize-leaf-dataset-tf-squeezenet/notebook>. Erişim: 04.10.2022
- Xu, L., Xu, X., Hu, M., Wang, R., Xie, C., & Chen, H. (2015). Corn leaf disease identification based on multiple classifiers fusion. Transactions of the Chinese Society of Agricultural Engineering, 31(14), 194-201.
- Zhang, F. (2013). Recognition of corn leaf disease based on quantum neural network and combination characteristic parameter. Journal of Southern Agriculture, 44(8), 1286-1290.
- Zhang, Z. Y., He, X. Y., Sun, X. H., Guo, L. M., Wang, J. H., & Wang, F. S. (2015). Image recognition of maize leaf disease based on GA-SVM. Chemical Engineering Transactions, 46, 199-204.
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 8697-8710).