

Şeker Kamışı Yaprak Hastalıklarını Farklı Derin Öğrenme Modellerinin Hibrit Bir Yöntemi ile Tespiti*

Mehmet Zahit UZUN^{1*} 

¹Karamanoğlu Mehmetbey Üniversitesi, Ermenek MYO., Bilgisayar Programcılığı, Karaman, TÜRKİYE.

Alındı/Received: 02/06/2025; Kabul/Accepted: 02/07/2025; Yayın/Published: 29/07/2025

Bu makale SABİT I. Uluslararası Disiplinlerarası Ermenek Kongresi'nde "Şeker Kamışı Yaprak Hastalıklarına Ait Görüntü Verilerinden Derin Özelliklerinin Çıkarılıp Bu Özelliklerin DVM ile Sınıflandırılması" adıyla özet metin olarak sunulmuştur.

Sorumlu yazar e-posta: mzuzun@kmu.edu.tr

Öz

Şeker kamışı bitkisinde karşılaşılan hastalıkların zamanında ve doğru teşhisi tarımsal faaliyetler açısından büyük önem taşımaktadır. Geleneksel yaklaşımların öznel, iş gücü ve uzman görüşü gerektiren zorlukları bulunmaktadır. Bu ihtiyaçlar doğrultusunda bu çalışmada hastalıkları otomatik olarak sınıflandıran derin öğrenme tabanlı bir model geliştirilmiştir. Araştırmada kullanılan SugarcaneLeafDisease veri seti kırmızı çürüklük, mozaik, pas, sarı hastalıkları ve sağlıklı olmak üzere 5 sınıftan oluşan toplam 2521 adet görüntüden oluşmaktadır. Görüntüler veri artırma tekniği kullanılarak çoğaltılmıştır. Çalışmada hibrit yaklaşım tercih edilmiş ve dört farklı derin öğrenme modeli kullanılmıştır. DenseNet, InceptionResNetV2, MobileNet ve Xception olmak üzere seçilen tüm modellerde ImageNet ağırlıkları kullanılarak transfer öğrenmesi gerçekleştirilmiştir. DenseNet ve MobileNet için görüntü girişleri 224x224; Xception ve InceptionResNet için giriş değerleri 299x299'dur. Modellerde toplu boyut 32, global ortalama havuzlama ve tam bağlı katmanlarda aktivasyon fonksiyonu "relu" kullanılmıştır. Tüm modellerin son katmanlarında önce 0.5 değerine sahip bırakma katmanı ardından 1000 nöronlu bir tam bağlantılı katman kullanıldı. Her modelin son tam bağlantılı katmanından 1000 özellik, toplam 4000 özellik Destek Vektör Makinesi (DVM) ile sınıflandırıldı. Rbf çekirdeği ve C:100, gamma=0.001 hiper parametresi ile %92.61 doğruluk, %92.66 kesinlik, %92.54 duyarlılık ve %92.57 F1 ölçümleri elde edildi. Deneysel çalışmalarda RepeatedStratifiedKfold 5 katlı çapraz doğrulama tekniği ve hiper parametreleri optimize eden GridCVSearch yöntemi kullanıldı. Sonuçlar, modelin geleneksel yöntemlere alternatif olabilecek potansiyel bir karar destek sistemi olabileceğini gösterdi.

Anahtar Kelimeler:Sınıflandırma,DVM, Derin Öğrenme, Şeker Kamışı Yaprığı, Özellik Çıkarma.

Detection of Sugarcane Leaf Diseases with A Hybrid Method of Different Deep Learning Models

Abstract

Timely and accurate diagnosis of diseases encountered by sugar cane plants is crucial for agricultural activities. Traditional approaches have difficulties that require subjective, laborious, and expert judgment. In line with these needs, a deep learning-based model that automatically classifies diseases was developed in this study. The Sugarcane Leaf Disease dataset used in the research consists of 2521 images of 5 classes: red rot, mosaic, rust, yellow diseases, and healthy. The photos were multiplied using the data augmentation technique. In the study, a hybrid approach was preferred, and four different deep learning models were used. Transfer learning was performed using ImageNet weights in all models selected, including DenseNet, InceptionResNet, MobileNet, and Xception. For DenseNet and MobileNet, the image inputs are 224x224; for Xception and InceptionResNet, the input values are 299x299. In the models, the batch size is 32, global average pooling, and the activation function "relu" is used in fully connected layers. In the last layers of all models, first a dropout layer with a value of 0.5 was used, then a fully connected layer with 1000 neurons was used. 1000 features from each model's last fully connected layer, a total of 4000 features, were classified with a Support Vector Machine (SVM). With Rbf kernel and C:100, gamma=0.001 hyperparameters, 92.61% accuracy, 92.66% precision, 92.54% sensitivity, and 92.57% F1 measurements were obtained. The RepeatedStratifiedKfold 5-fold cross-validation technique and GridCVSearch method, optimizing hyperparameters, were used in experimental studies. The result showed that the model could be a potential decision support system alternative to traditional methods.

Key Words: Classification, SVM, Deep learning, Sugarcane Leaf Disease, Feature Extraction.

Atf / Töcite:Uzun, MZ. (2025).Şeker Kamışı Yaprak Hastalıklarını Farklı Derin Öğrenme Modellerinin Hibrit Bir Yöntemi ile Tespiti. Karamanoğlu Mehmetbey Üniversitesi Ermenek Akademi Dergisi 2(1): 08-16.

1.GİRİŞ

Günümüzde dünyada üzerinde 120'den fazla Çin' de ise 60' dan fazla şeker kamışı hastalığı bildirilmiştir. Şeker kamışı mevsim normallerinin dışına çıkıldığında, ilkbahar aylarında yağış ve sıcaklık düşüşü birçok hastalığın yanı sıra kırmızı çürüklük hastalığına, yaz mevsiminde yüksek sıcaklık ve nemle birlikte birçok hastalığın yanı sıra pas, sarı leke hastalığına neden olmaktadır. Şeker kamışı alanlarına ekilen tehlikeli tohum kamışlarıyla taşınan hastalıklardan biride mozaik hastalığı ve sarı yaprak hastalığıdır (Huang ve ark. 2018).

Şeker üretiminde ve biyoenerji endüstrisinde kullanılan şeker kamışı mahsulleri tarımsal ürünler arasında %80 üretim oranına sahiptir (Li ve ark. 2023). Pas, mozaik, kırmızı çürüklük ve sarı leke hastalığı ekonomik kayıplara da neden olabilen hastalıklardır (Hughes 1978). Şeker kamışı bitkisinin karşılaştığı hastalıkları doğru ve zamanında tespit ve tanımlanması üreticiler ve ülke ekonomileri açısından hayati öneme sahiptir. Geleneksel yaklaşımların öznel, iş gücü ve uzman görüşü gerektiren zorlukları bulunmaktadır. Hızlı yayılan hastalıkları zamanında, doğru ve güvenilir bir şekilde teşhis edebilen bir sistemin varlığı üretim kalitesini ve niceliğini arttıracaktır. Geleneksel sistemlerin aksine makine öğrenmesi ve yapay zekanın alanlarının geliştiği günümüzde, bitkisel hastalıkları otomatik tanıma görevlerinde bu alanlarda başarılı olmuş birçok çalışma bulunmaktadır. Literatürde bu alanlarda yapılan çalışmalar incelenmiştir.

Ratnasari ve ark. (Ratnasari ve ark. 2014), RGB renk uzayına sahip şeker kamışı yaprak lezyon görüntülerinden renk özelliklerini ve doku özelliklerini çıkardılar. Daha sonra şeker kamışı leke hastalığı sınıflandırması için %80'lik bir doğruluğa ulaşmak için DVM (Destek Vektör Makinesi)' yi kullandılar. SugarcaneLeafDisease(Daphal ve Koli 2024b) veri seti kullanılarak yapılan sınıflandırma görevinde «Dikkat Tabanlı Çok Seviyeli Kalıntı Evrişimli Sinir Ağı» modelini önermişlerdir. Önerdikleri model %86,53 doğruluk ile VGGNet, ResNet50-v2, XceptionNet, ve EfficientNet-B7 modellerinden daha başarılı sonuç vermiştir. Yapılan bir diğer çalışmada (Rajput ve ark. 2024), açık kaynaklı veri tabanlarından çok çeşitli şeker kamışı yaprağı görüntüleri bir araya getirdiler. Modifiye ettikleri evrişimsel sinir ağı (ESA) ve DVM ile şeker kamışı yaprağı hastalıklarını 12 farklı kategoride sınıflandırdılar. Modelin ortalama ölçümleri %75.25 hassasiyet, %75.51 kesinlik, %75.28 F1 puanı olarak elde etmişlerdir. Rajput ve ark. (Rajput ve ark. 2024), kendi oluşturdukları ESA ve DVM'nin kullanıldığı bir çalışma önermişlerdir. Modellerinde kullandıkları ESA üç evrişimsel katmana ve bu üç katman arasında maksimum havuzlama yapan iki katmana sahiptir. Bu katmanların sonunda ise 1024 ve 512 nörondan oluşan tam bağlı katman bulunmaktadır. Tam bağlı katmanların çıkışında ise özellikler bir rbf-DVM sınıflandırıcısı ile sınıflandırılmıştır. Modelin ortalama doğruluğu için yapılan ölçümlerde %88 ile %92 arasında değişen değerler bulunmuştur. Singh ve ark. (Singh ve ark. 2024), evrişimsel, toplu normalleştirme, maksimum havuzlama, bırakma ve tam bağlı katmanlardan oluşan kendi tasarladıkları mimarileri şeker kamışı yaprak hastalıkları görüntülerini sınıflandırmak için kullanmışlardır. Beş sınıftan oluşan veri seti üzerinde mimarilerinin genel doğruluğu 0.91 olarak ölçülmüştür. Daphal ve Koli (Daphal ve Koli 2023), kamuya açtıkları ve bu çalışmada da faydalanan veri setleri için çeşitli transfer öğrenme yaklaşımlarını deneysel testlerinde kullanmışlardır. ESA'ları karşılaştırmalı kullandıkları çalışmada Xception, ResNet50, VGG19, MobileNetV2 ve EfficientB7 modelleri arasında en başarılı model olan MobileNetV2'de %84'lük bir doğruluk elde etmişlerdir. Ayrıca önerdikleri derin öğrenme tabanlı yığılma adındaki modelleri ile de %86.53 lük bir doğruluk elde etmişlerdir. Bu model sıralı ESA modeli ve uzamsal özelliklerin dikkate alındığı ESA modellerinin birleştirildiği bir model olarak tanıtmışlardır.

Şeker kamışı yaprağı hastalığını tespit etmede otomatik yaklaşımlardan biri de derin öğrenme modellerinden olan ESA'larıdır. Bunları eğitebilmek için büyük veri setlerine ihtiyaç duyulmaktadır. Ancak transfer öğrenme ile büyük veri setlerine olan ihtiyaçlar büyük oranda azalmıştır (Daphal ve Koli 2023). Büyük veri setlerinde eğitilen bu modellerin ağırlıklarına ulaşarak yeni öğrenme ortamında başlangıç ağırlık olarak kullanılabilir. Literatür araştırmalarımız sonucu mevcut ESA'lar ile birlikte transfer öğreniminin süre ve maliyet kazancından dolayı şeker kamışı yaprak hastalıkları alanındaki bu çalışmada tercih etmemize sebep olmuştur. Ayrıca makalede SugarcaneLeafDisease veri seti, görüntülerin kamuya açık olması, sınıf dağılımı bakımından homojene yakın olması gibi sebeplerden dolayı tercih edilmiştir.

Şeker kamışı, küresel şeker üretiminin büyük bir oranına sahipken ayrıca etanol gibi kimyasal üretimler için bir ham madde (Sun ve ark. 2023) olarak kullanılan önemli bir tarım ürünüdür. Bu çalışmanın amacı şeker kamışı hastalıklarını güvenilir bir şekilde teşhis edebilen derin öğrenme tabanlı bir model geliştirerek, geleneksel ve


manuel yaklaşımların zorluklarına çözüm bulmayı hedeflemektedir. Donanımsal gelişmelerin ardından tüm alanlarda olduğu gibi tarımsal endüstride de yapay zekâ uygulamaları artarak gelişmektedir. Bu çalışma, birbirinden farklı ESA'ların kendilerine özgün mimarilerini birleştirerek daha güçlü bir hibrit model literatüre sunmayı amaçlamaktadır.

Makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2 'de Şeker kamışı yaprağı görüntülerinin sınıflandırılmasında önerilen modelimizi ayrıntılı bir şekilde tanıtıyoruz. Bölüm 3'de deneysel çalışmalarımıza ait bulgular detaylı bir şekilde sunuyoruz. Literatürdeki diğer çalışmalarla karşılaştırıp modelimizin üstün ve geliştirilmesi gereken yönlerini tartışıyoruz. Bölüm 4'de ise önerilen çalışmamızın sonuçlarını ve şeker kamışı yaprak hastalığını teşhisinde geliştirilebilecek bazı öneriler sunuyoruz.

2. METERYAL VE METOT

2.1. Önerilen Model

Önerilen modelin yapısı veri seti, veri artırma, öznetelik çıkarma ve sınıflandırma adımlarından oluşmaktadır. Bu bölümde, beş kategoriye ayrılmış şeker kamışı yaprağı görüntülerinden hastalık tipini veya sağlıklı olup olmadığını tespit etmek için, önerilen modeli inceleyeceğiz. Önerilen model dört aşamadan oluşmaktadır. İlk aşamada kamuya açık veri setine ait görüntüler model girdisi için kullanılmıştır. İkinci aşamada veri setindeki örnek sayısını çoğaltıp eğitimi iyileştirmek için veri artırma teknikleri kullanılarak örnek sayısı beş katına çıkarılmıştır. Üçüncü aşamada görüntülerden özellik haritası çıkarmak için dört farklı ESA modeli DenseNet-169, MobileNet, InceptionResNetV2, Xception kullanılmıştır. Bu dört mimarinin en üst katmanları önerilen hibrit modelde dahil edilmeyip "include_top" parametresi "False" olarak belirlenmiştir. ESA'ların sonuna %50 bırakma katmanı ve 1000 nöronlu tam bağlı katman eklenmiştir. Her ESA sonuna eklenen 1000 nörondan alınan özellik haritaları birleştirilerek 4000 özellik haritası elde edilmiştir. Son olarak birleştirilmiş bu özellik haritalarını sınıflandırmak için DVM kullanılmıştır. Modelin yapısı Şekil 1'de verilmiştir.



Şekil 1. Şeker kamışı yaprağı hastalığı veri setinin sınıflandırılması için önerilen mimarinin genel yapısı

Özellik çıkarma aşamasında seçilen ESA mimarilerinin tercih edilme nedenleri şu şekildedir:

- Xception mimarisinin avantajı, derinlemesine ayrışabilir ve noktasal evrişim işlemlerini yapısında bulundurarak parametre sayısını ve maliyetini büyük oranda düşürmektedir (Chollet 2017).

- MobileNet mimarisinin avantajı, derinlemesine ayrışabilir evrişim ve gecikme ile doğruluk arasında verimli denge kuran basit iki küresel hiper parametreyi yapısında bulundurmaktadır (Howard ve ark. 2017).
- InceptionResNetV2 mimarisinin avantajı, hesaplama maliyet açısından verimli Inception mimarisinin yanı sıra modelin eğitimini önemli ölçüde hızlandıran artık bağlantıları yapısında bulundurmasıdır (Szegedy ve ark. 2017).
- DenseNet mimarisinin avantajı, daha az parametre ve hesaplama yükünün yanı sıra her katmanı önceki tüm katmanlara ait özellik haritalarını girdi olarak alan ileri beslemeli bağlantılarının bulunmasıdır. Sonuç olarak kaybolan gradyan sorununu hafifletir, özellik yayılımını güçlendirerek parametre sayısını önemli oranda azaltır (Hughes 1978).

DVM algoritması ile sınıflandırma için çok sayıda çekirdek, gama ve marj hiper parametresi arasından en başarılı olanlar GridCVSearch tekniği kullanılarak seçilmiştir. Birleştirilen özneliklerin en başarılı sınıflandırma ölçümleri için modelin hiper parametreleri $C=0.001$ ve radyal baz fonksiyonu (rbf) çekirdeği elde edilmiştir. Son olarak RepeatedStratifiedKfold 5-kat çapraz doğrulama tekniği ile model ölçümlerinin ortalaması alınmıştır.

2.2. Veri Seti

Kamuya açık şeker kamışı yaprağı hastalığı veri seti farklı hava koşullarında ve farklı tarlardan akıllı telefon kullanılarak elde edilmiştir. Görüntü örnekleri gün içerisinde görüntü kalitesi yüksek veriler elde edilebilecek hava koşullarında toplanmıştır (Daphal ve Koli 2023). Bu koleksiyon, şeker kamışı yapraklarında sık görülen dört hastalık türü pas, mozaik, kırmızı çürüme ve sarı hastalığı görüntüleri ve sağlıklı görüntüler olmak üzere beş sınıf içeren bir veri setidir (Daphal ve Koli 2024b). Bu görüntüler daha sonra deneyimli çiftçiler tarafından etiketlendirilip ayrıca bölgesel tarım görevlileri tarafından doğrulanmıştır (Daphal ve Koli, 2024a). Yazarlar paylaştıkları veri seti için verdikleri adreste (Daphal ve Koli 2025) bulunan örnek sayısı ile çalışmalarında belirttikleri örnek sayısı farklılık göstermektedir. Kullandıkları veri setindeki sınıfların örnek sayıları ve bu çalışmada kullanılan örnek sayıları Tablo1’de verilmiştir.

Tablo 1. Model için kullanılan şeker kamışı yaprağı hastalığına ait örneklerin kategorileri.

Kategori Adı	Yazarların kullandıkları örnek sayısı	Bu çalışmada kullanılan örnek sayısı
Sağlıklı	520	522
Pas	514	514
Kırmızı çürüklük	519	518
Sarı	505	505
Mozaik	511	462
Toplam	2569	2521

2.3. Veri Artırma

Veri artırma, derin öğrenme modellerinde yaygın olarak kullanılan, modelin genelleme yeteneğini yükselten bir tekniktir (Karadeniz ve ark. 2023). Veri artırma tekniği şeker kamışı yaprağı hastalığından oluşan veri setindeki örnekler üzerine uygulanmıştır. Böylece veri setindeki örnekler 5 kat çoğaltılarak 2521 görüntüden 12605 görüntüye ulaşıldı. Görüntülere, yatay ve dikey yansıtma işlemi 0.5 olasılıkla, ölçekleme işlemi (0.8 ila 1.2) arasında, görüntüleri döndürme işlemi (0 ila 45) derece arasında, görüntüleri kaydırma (-0.2 ila 0.2) arasında, x eksenine paralel eğme işlemi (-15 ila 15) derece ile gerçekleştirildi.

2.4. ESA ile Özellik Çıkarma

ESA, evrişimsel katmanlar vasıtası ile çok boyutlu özellik çıkarma yöntemidir (Başaran 2022). Soldan sağa ve yukarıdan aşağıya görüntü üzerindeki pikselleri tarayan çeşitli filtre boyutları ile özellik çıkarma işlemi gerçekleştirilmektedir. ESA’nın ilk katmanlarında görüntüye ait kenar özellikleri gibi daha somut bilgiler çıkarılırken ilerleyen katmanlarda daha soyut ve ayrıntılı bilgiler elde edilmektedir (Karadeniz ve ark. 2023). Bu çalışmada kullanılan ESA modelleri ve deneysel testlerde kullanılan hiper parametreler Tablo2’de verilmiştir.

Tablo 2. Seçilen ESA modelleri ve hiper parametreleri.

Model	Ağırlıklar	En üst katmanlar	Giriş boyutları	Parti boyutu	Özelliklerin elde edildiği katman
MobileNet	ImageNet	Yok	224*224*3	32	conv pw 13 relu
DenseNet-169	ImageNet	Yok	224*224*3	32	Relu

Xception	ImageNet	Yok	299*299*3	32	block14_sepconv2_act
InceptionResNetV2	ImageNet	Yok	299*299*3	32	conv_7b_ac

Modellerde “ImageNet” ağırlıkları başlangıç ağırlığı olarak seçildiğinden tüm modellerde transfer öğrenme gerçekleştirilmiştir. MobileNet ve DenseNet-169 için giriş boyutları varsayılan değer olan 224x224x3, Xception ve InceptionResNetV2 için giriş boyutları varsayılan değer olan 299x299x3 kullanılmıştır. Batch_size değeri ise en fazla tercih edilen değer olan 32 seçilmiştir. Modeller ile sadece özellik çıkarma işlemi yapıldığından en üst katmanları kullanılmamıştır (include_top=False). Özellikler MobileNet için conv_pw_13_relu katmanından, DenseNet-169 için conv5_block32_concat katmanından sonra gelen toplu normalleştirme katmanından sonraki katman olan Relu katmanından, Xception modeli için block14_sepconv2_act katmanından, InceptionResNetV2 modeli için conv_7b_ac katmanından elde edilmiştir. Ardından tüm modellerde bu katmanlardan sonra global ortalama havuzlama işlemi, sonrasında %50 oranında bırakma katmanı ve 1000 nöronlu tam bağlı katman kullanılmıştır.

2.5. DVM (Destek Vektör Makinesi) ile Sınıflandırma

DVM, denetimli öğrenme görevlerindeki sınıflandırma ve regresyon analizi problemlerini çözmede en verimli algoritmalarından biri olarak gösterilmektedir (Tonkal ve ark. 2021). DVM’nin veri setindeki örnekleri iki ya da daha fazla sınıfa ayırdığı düzlemdeki sınıflara ait en uç örneklerin sınır çizgisine destek vektör adı verilir. Eğer DVM linear bir düzlemde örnekleri başarılı bir şekilde ayıramaz ise bu sefer çekirdek fonksiyonları kullanıp örnekleri bir üst düzleme taşıyarak burada sınıflandırmaya çalışmaktadır. Bu çalışmada da linear, poly, rbf ve sigmoid çekirdekleri karşılaştırılarak en başarılı ölçümlerin elde edildiği rbf-DVM kullanılmıştır. SugarcaneLeafDiseaseDataset örneklerini sınıflandırmada kullanılan DVM parametreleri Tablo3’de belirtilmiştir.

Tablo 3. Model için kullanılan sınıflandırıcıya ait parametreler.

Çekirdek	Gama	C	Örnek Sayısı	Özellik Sayısı
rbf	0.001	100	12605	4000

3. BULGULAR VE TARTIŞMA

Önerilen model ve yapılan deneysel çalışmalarda hedeflenen temel özellikler şunlardır: özgün bir model oluşturma, şeker kamışı yaprağı hastalığı örneklerinin özelliklerini elde etmek için en başarılı derin öğrenme modellerinin karşılaştırılması ve seçilmesidir. Yapılan deneysel çalışmalarda macOS işletim sistemi, Apple M1 Pro işlemci, 8 çekirdek CPU, 14 çekirdek GPU, 32 Gb LPDDR5 RAM özelliklerine sahip bir dizüstü bilgisayar kullanılmıştır. Python programlama dili ve Sklearn, Numpy, Matplotlib, OpenCV, Tensorflow’a ait keras kütüphaneleri kullanılmıştır.

Kamuya açık şeker kamışı yaprağı hastalığı veri seti her sınıfta olarak yaklaşık 500 örneğin bulunduğu kırmızı çürüklük, mozaik, pas, sarı hastalıkları ve sağlıklı olmak üzere 5 sınıftan oluşmaktadır. Önerilen modelde öncelikle görüntülerin farklı derin öğrenme yöntemiyle özellikleri çıkarılmıştır. Ardından en iyi ölçümleri veren dört derin modelin özellikleri birleştirilmiştir. Son olarak birleştirilmiş özellikler DVM ile sınıflama süreci sonunda modele ait sonuçlar elde edilmiştir. Bu sonuçları elde ederken yapılan deneysel testler ve sonuçları bu bölümde anlatılacaktır.

Derin öznetelik çıkarmak için DenseNet-169, MobileNet, Xception, InceptionResNetV2, InceptionV3 modelleri karşılaştırılmıştır. Modellerden çıkarılan özellikler, %50 bırakma ve tam bağlı katmandan sonra elde edilmiştir. Özellik çıkarımında kullanılan derin öğrenme modellerinin DVM ile sınıflandırılmasına ait deneysel test sonuçları Tablo 4’de verilmiştir.

Tablo 4. Model için seçilecek ESA modellerinin karşılaştırılması.

Model	Doğruluk	Kesinlik	Duyarlılık	F1	Özgüllük	C	Gama	Çekirdek
DenseNet-169	0.8536	0.8544	0.8524	0.8528	0.9634	0.1	0.01	poly
MobileNet	0.847	0.8485	0.8454	0.8459	0.9617	0.1	0.01	poly
Xception	0.8185	0.8177	0.8172	0.8168	0.9546	10	0.1	rbf
InceptionResNetV2	0.8131	0.8171	0.8113	0.8118	0.9533	10	0.01	rbf
InceptionV3	0.8017	0.8022	0.8007	0.8004	0.9504	100	0.01	rbf

Deneysel test sonuçlarına göre en başarılı sonucu DenseNet-169 modelinden elde edilmiştir. Buna göre DenseNet-169 modelinden elde edilen doğruluk 0.8536, kesinlik 0.8544, duyarlılık 0.8524, F1 değeri 0.8528 ve özgüllük değeri 0.9634 olarak ölçülmüştür. Başarı sırasına göre diğer modeller ise sırasıyla MobileNet,

Xception, InceptionResNetV2 ve InceptionV3 olarak belirlenmiştir. Bu beş model içerisinde en başarılı dördü seçilerek bir sonraki deneysel test için belirlenmiştir.

Sonraki deneyde en başarılı dört modelin özellikleri %50 bırakma ve tam bağlı katmandan sonra elde edilerek birleştirilmiştir. En başarılı dört modeli birleştirme işlemini gerçekleştirme nedenimiz görüntülere ait özellik çeşitliliği ile özellik zenginliği hedefleyerek sınıflandırma doğruluğunu artırmaktır. Tablo 5’de birleştirilmiş özelliklerin DVM ile sınıflandırılmasına ait ölçümler verilmiştir.

Tablo 5. Önerilen modelin sınıflandırma sonuçları ve optimum hiper parametreleri.


Model	Doğruluk	Kesinlik	Duyarlılık	F1	Özgüllük	C	Gama	Çekirdek
Önerilen Model	0.8983	0.8993	0.8973	0.8978	0.9745	100	0.001	rbf
Veri artırımı ile Önerilen Model	0.9261	0.9266	0.9254	0.9257	0.9815	100	0.001	rbf

Bu ölçümlerin ilkinde 2521 örnekten oluşan doğal veri seti kullanılmıştır. Diğerleri ise görüntüyü artırma tekniği kullanarak veri setini 5 kat çoğaltılarak elde edilen 12605 örneğin sonuçlarıdır. Hedeflenen zengin özellik seti başarılı sonuçlar vererek tüm deneysel testler içerisindeki en iyi sonuçlar ölçülmüştür. Buna göre çoğaltılmış verilerden doğruluk 0.9261, kesinlik 0.9266, duyarlılık 0.9254, F1 değeri 0.9257 ve özgüllük değeri 0.9815 sonuçları elde edilmiştir. Artırılmış veri seti ile önerilen model için yapılan deneysel çalışmaya ait karmaşıklık matrisi Şekil 2’de verilmiştir. Karmaşıklık matrisi hangi sınıfların daha kolay hangi sınıfların daha zor ayırt edildiğini göstermektedir.

Sağlıklı	95	3	0	0	1
Mozaik	6	90	1	1	2
Kırmızı Çürük	1	1	93	2	4
Pas	1	1	2	95	1
Sarı	4	2	4	1	89
	Sağlıklı	Mozaik	Kırmızı Çürük	Pas	Sarı

Şekil2. Önerilen modelin karmaşıklık matrisi.

Artırılmış veri seti ile önerilen model için yapılan deneysel çalışmaya ait Alıcı-İşlem Karakteristiği grafiği Şekil 3’ de sunulmuştur. Alıcı-İşlem Karakteristiği grafiği isabetli ve yanlış tahminleme arasındaki oranı göstermektedir.



Şekil 3. Önerilen modelin Alıcı-İşlem Karakteristiği eğrisi.

Bu çalışmada önerilen modelin diğer modellerle karşılaştırıldığı sonuçlar ise Tablo 6’da verilmiştir.

Tablo 6. Aynı ve benzer veri setleri kullanan modellerin karşılaştırılması.

Metot	Veri Seti	Sample	Doğruluk	Sınıf
AMRCNN (SwapnilDadabhauDaphal& Koli, 2024b)	SugarcaneLeafDisease	2569	%86.53	5
MobileNet-V2(SwapnilDadabhauDaphal& Koli, 2024a)	SugarcaneLeafDisease	12845	%87	5
EsembeDeep Learning (SwapnilDadabhauDaphal& Koli, 2023)	SugarcaneLeafDisease	2569	%86.53	5
ResNet(S D Daphal& Koli, 2021)	SugarcaneLeaves	1470	%90.62	5
VGG-16(S. D. Daphal& Koli, 2021)	SugarcaneLeaves	1470	%81.25	5
Önerilen Model	SugarcaneLeafDisease	12605	%92.61	5

Yazarlar ResNet ve VGG16 ile yapmış oldukları çalışmada kullandıkları veri setindeki örnek sayısı hem yetersiz hem de örneklerin sınıflara dağılımı homojen değildir. Buna rağmen veri artırma teknikleri kullanılmamıştır. Kullandıkları mimarilerde son teknoloji mimarilere göre nispeten eski kalmıştır. MobileNet-V2 ile yapılan çalışmada bizim çalışmamızda kullandığımız kendilerine ait veri seti ve aynı miktarda beş kat veri artırma kullanılmıştır. Bizim çalışmamızın bu çalışmaya göre avantajı, bir mimari yerine dört farklı mimarinin kendine ait farklı avantajını birleştirerek özellik haritalarını zenginleştirdik. Buda hem modelin performansını artırırken hem de literatüre yenilikçi bir katkı sağladığı görüşündeyiz. Ayrıca çalışmamızın bu çalışmadan bir diğer farkı, dört mimarinin her birinde transfer öğrenme kullanarak, öğrenmeyi sıfırdan başlatmamış olduk. EsembeDeep Learning adlı çalışmada, yığın topluluğu adını verdikleri, farklı modellerin tahminlerini birleştirerek nihai bir tahmin üretmeyi öğrenen bir topluluk modeli önermişlerdir. Yazarlar bu modelin küçük veri setlerinde transfer öğrenmenin kullanıldığı VGG19, ResNet50, Xception, MobileNet V2 ve EfficientNet_B7 modellerinden üstün olduğunu ölçümlemişlerdir. Büyük veri setlerinde ise hesaplama maliyetinin pahalı ve zor olabileceğine değinmişlerdir. Yazarlar AMRCNN adlı çalışmada ise uzamsal dikkat tabanlı artık bloklardan oluşan derin öğrenme mimarisi önermişlerdir. Bu modelin, kendi oluşturdukları şeker kamışı yaprak hastalığı veri seti üzerinde VGG19, ResNet50, Xception ve EfficientNet_B7 gibi modellerden başarılı performans verdiğini belirtmişlerdir. Yazarlar önerdikleri bu modelde de veri artırma yapmamışlardır. Ayrıca hem kendi çalışmamızda hem de diğer çalışmalarda veri önileme yapılmaması bizim tarafımızdan eksiklik olarak görünmektedir.

4. SONUÇ

Bu çalışmayla kamuya açık şeker kamışı yaprağı hastalığı görüntülerinden hastalığın türünü ayırt edebilen yeni bir hibrit model ortaya konmuştur. Kullanılan veri seti beş sınıftan oluşmaktadır. Bu sınıflar; kırmızı çürüklük, mozaik, pas, sarı hastalıkları ve sağlıklı görüntü verileridir. Önerdiğimiz modelinin sınıflandırma başarısı önceki çalışmalarla karşılaştırıldığında rekabetçi ve en başarılı model olduğu gözlemlenmiştir. Önerilen modelin yenilikçi ve ayırt edici özelliği birden fazla derin öğrenme modeli kullanılarak her bir modelin kendine ait

mimari avantajlarından faydalanılmıştır. Böylece DVM sınıflandırıcısı ile elde edilen sınıflandırma başarısı %92,61 olmuştur.

Gelecekte, görüntü dönüştürücü tabanlı modeller ve farklı evrimsel sinir ağları kullanılarak elde edilen özellik haritaları ile daha iyi sonuçlar elde edilebilir. Etkili bir önışleme yapılarak daha iyi bir eğitim ve sınıflandırma başarısı elde edilebilir. Farklı sınıflandırıcılar şeker kamışı yaprağı hastalığı görüntülerinde karşılaştırılabilir. Ayrıca bu çalışmada kullanılan modelden, gelecekte şeker kamışı yaprağı hastalığı tanıma görevinde mobil bir cihaz uygulaması olarak faydalanılabilir.

KAYNAKLAR

- Başaran E (2022). A new brain tumor diagnostic model: Selection of textural feature extraction algorithms and convolution neural network features with optimization algorithms. *Computers in Biology and Medicine*, 148, 105857. <https://doi.org/https://doi.org/10.1016/j.compbiomed.2022.105857>.
- Chollet F (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Daphal SD, Koli SM (2021). Transfer Learning approach to Sugarcane Foliar disease Classification with state-of-the-art Sugarcane Database. In *2021 International Conference on Computational Intelligence and Computing Applications (ICCICA)*, 1-4. <https://doi.org/10.1109/ICCICA52458.2021.9697312>.
- Daphal SD, Koli SM (2023). Enhancing sugarcane disease classification with ensemble deep learning: A comparative study with transfer learning techniques. *Heliyon*, 9(8). <https://doi.org/10.1016/j.heliyon.2023.e18261>.
- Daphal SD, Koli SM (2024a). Enhanced Classification of Sugarcane Diseases Through a Modified Learning Rate Policy in Deep Learning. *Traitement du Signal*, 41(1), 441-449. <https://doi.org/10.18280/ts.410138>.
- Daphal SD, Koli SM (2024b). Enhanced deep learning technique for sugarcane leaf disease classification and mobile application integration. *Heliyon*, 10(8). <https://doi.org/10.1016/j.heliyon.2024.e29438>.
- Daphal S, Koli S (2025, Mayıs 4). Sugarcane Leaf Disease . <https://data.mendeley.com/datasets/9424skmnrk/1>.
- Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Andreetto M, Adam H (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXivpreprint arXiv:1704.04861*.
- Huang YK, Li WF, Zhang RY, Wang XY, Huang YK, Li WF, Zhang RY, Wang XY (2018). Diagnosis and control of sugarcane important diseases. In *Color Illustration of Diagnosis and Control for Modern Sugarcane Diseases, Pests, and Weeds*, 1-103.
- Hughes CG (1978). Diseases of Sugarcane — a Review. *PANS*, 24(2), 143-159. <https://doi.org/10.1080/09670877809411604>.
- Karadeniz AT, Başaran E, Celik Y (2023). Identification of walnut variety from the leaves using deep learning algorithms. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12(2), 531-543. <https://doi.org/10.17798/bitlisfen.1263130>.
- Karadeniz AT, Çelik Y, Başaran E (2023). Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model. *European Food Research and Technology*, 249(3), 727-738. <https://doi.org/10.1007/s00217-022-04168-8>.
- Li X, Li X, Zhang S, Zhang G, Zhang M, Shang H (2023). SLViT: Shuffle-convolution-based lightweight Vision transformer for effective diagnosis of sugarcane leaf diseases. *Journal of King Saud University - Computer and Information Sciences*, 35(6), 101401. <https://doi.org/https://doi.org/10.1016/j.jksuci.2022.09.013>.
- Rajput K, Manwal M, Chauhan RK, Kukreja V, Mehta S (2024). Transforming Sugarcane Leaf Diseases Pathology with Convolutional Neural Networks and SVM. *2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, 1-6. <https://doi.org/10.1109/ICRITO61523.2024.10522214>.
- Rajput K, Manwal M, Kukreja V, Mehta S (2024). Enhancing Crop Health: CNN-SVM Fusion for Sugarcane Leaf Disease Analysis. *2024 3rd International Conference for Innovation in Technology (INOCON)*, 1-5. <https://doi.org/10.1109/INOCON60754.2024.10511764>.

- Ratnasari EK, Mentari M, Dewi RK, Ginardi RVH (2014). Sugarcane leaf disease detection and severity estimation based on segmented spots image. In Proceedings of International Conference on Information, Communication Technology and System (ICTS) 2014, 93-98. <https://doi.org/10.1109/ICTS.2014.7010564>.
- Singh R, Sharma N, Pal A (2024). Optimized Deep Learning Approaches for Sugarcane Leaf Disease Classification Using CNN Model. 2024 5th International Conference on Data Intelligence and Cognitive Informatics (ICDICI), 598-603. <https://doi.org/10.1109/ICDICI62993.2024.10810874>.
- Sun C, Zhou X, Zhang M, Qin A (2023). SE-VisionTransformer: Hybrid network for diagnosing sugarcane leaf diseases based on attention mechanism. Sensors, 23(20), 8529.
- Szegedy C, Ioffe S, Vanhoucke V, Alemi A (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In Proceedings of the AAAI conference on artificial intelligence, 31(1).
- Tonkal Ö, Polat H, Başaran E, Cömert Z, Kocaoğlu R (2021). Machine learning approach equipped with neighbourhood component analysis for DDoS attack detection in software-defined networking. Electronics, 10(11). <https://doi.org/10.3390/electronics10111227>.