

GAZİ
JOURNAL OF ENGINEERING SCIENCES

Detection of Rice Plant Diseases Based on Deep Transfer Learning

Necaattin Barışçı^{a*}, Merve Güllü^b, İbrahim Alper Doğru^c

Submitted: 16.11.2023 Revised: 05.12.2023 Accepted: 08.12.2023 doi:10.30855/gmbd.0705S10

ABSTRACT

Keywords: rice plant diseases, deep learning, transfer learning

^{a*} Gazi University,
 Technology Faculty,
 Dept. of Computer Engineering
 06560 - Ankara, Türkiye
 Orcid: 0000-0002-8762-5091
 e mail: nbarisci@gazi.edu.tr

^b Gazi University,
 Technology Faculty,
 Dept. of Computer Engineering
 06560 - Ankara, Türkiye
 Orcid: 0000-0001-7442-1332

^c Gazi University,
 Technology Faculty,
 Dept. of Computer Engineering
 06560 - Ankara, Türkiye
 Orcid: 0000-0001-9324-7157

*Corresponding author:
 nbarisci@gazi.edu.tr

Rice, obtained through the processing of paddy, is one of the most widely consumed food products globally. However, diseases affecting rice plants, particularly those occurring on the rice leaves, pose significant challenges for farmers. The identification of rice plant diseases demands specialized knowledge, making it a complex issue to tackle. Often, due to insufficient understanding, farmers misdiagnose diseases and apply incorrect treatments. Rapid and accurate disease diagnosis plays a pivotal role in enhancing healthy and productive crop cultivation. To address this problem, a deep learning-based model was developed to detect rice plant diseases. The model was trained on a dataset containing four different rice plant diseases and achieved a successful outcome with a loss value of 0.0014. Additionally, four different deep learning algorithms were used to create models through transfer learning with pre-trained ImageNet models, and a comparison of their performance was presented. The most successful model was obtained using the VGG16 transfer learning architecture. Experimental results in this study demonstrate that the proposed transfer learning method can effectively recognize rice leaf diseases, providing a reliable approach for identifying leaf diseases in various plants.

Derin Transfer Öğrenmeye Dayalı Pirinç Bitkisi Hastalıklarının Tespiti

ÖZ

Çeltiğin işlenmesi sonucu elde edilen pirinç, dünyada en çok tüketilen gıda ürünlerinden bir tanesidir. Bitki yapraklarında özellikle, çeltik yapraklarında oluşan hastalıklar çiftçilerin karşılaştığı önemli sorunlardan biridir. Çeltik bitkisi hastalıkları uzman bilgisi gerektirdiğinden dolayı zor bir problemdir. Çiftçiler mahsul hastalıkları hakkında yeterince bilgi sahibi olmadıklarından dolayı hastalık için yanlış tespit yapılmakta ve yanlış tedavi uygulanmaktadır. Hastalıkların hızlı ve doğru olarak tanınması, sağlıklı ve verimli üretimin artmasındaki en önemli süreçtir. Bu tür problemlere çözüm sunmak amacıyla çeltik bitkisi hastalıklarını tespit eden derin öğrenme tabanlı bir model geliştirilmiştir. Dört farklı çeltik bitkisi hastalığı içeren veri kümesi üzerinde model eğitilmiş ve 0,0014 kayıp değeri ile başarılı bir model oluşturulmuştur. Eğitilmiş ImageNet modelleri üzerinde transfer öğrenme metodu ile modeller oluşturmak için dört farklı derin öğrenme algoritması kullanılmış ve bu modellerin performansları karşılaştırılmıştır. En başarılı model VGG16 transfer öğrenme mimarisini ile elde edilmiştir. Deneysel sonuçlar, bu çalışmada önerilen transfer öğrenme yönteminin pirinç yaprağı hastalıklarını tanıyabildiğini ve bunun da birçok bitkinin yaprak hastalıklarını tanımak için güvenilir bir yöntem sağladığını göstermektedir.

Anahtar Kelimeler: çeltik bitkisi hastalıkları, derin öğrenme, transfer öğrenme

1. Giriş (Introduction)

2021-2022 yılı arasında pirinç, tahıl üretiminde 509,87 milyon ton ile üçüncü sırada yer almaktadır [1]. Enerji kaynağında temel gıda olarak pirinç, dünya nüfusunun yarısından fazlası tarafından tüketilmektedir [2]. Özellikle Asya, Latin Amerika ve Afrika bölgelerinde pirinç beslenmenin hayati bir parçası olarak kabul edilmektedir. Dünya çapında insanlar tarafından tüketilen kalorinin beşte birinden fazlasının pirinçten sağlandığı tahmin edilmektedir [3].

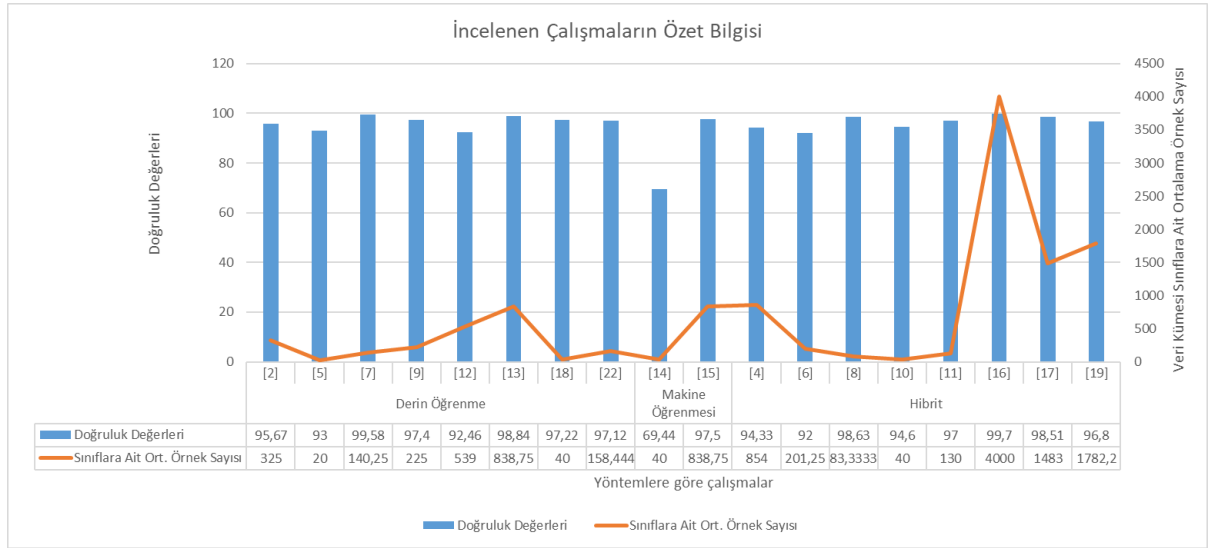
Çeltik bitkisinin üretimini ve kalitesini etkileyen hastalıkların teşhisi sayesinde hastalıkların tedavisini gerçekleştirmek ve yayılmasının önüne geçmek hedeflenmektedir. Bitki hastalıklarının teşhisi, alanında uzman kişilerin tanısını gerektirir [1-24]. Ayrıca hastalıkların çeşitli belirtileri arasında benzerlikler olması ve hastalıkların ilk zamanlarda ayırt edilememesi büyük problemlerdir. Bu nedenlerden dolayı hastalık tanısı maliyetli ve uzun bir süreç almaktadır. Literatürde bu problemi çözmek için yapay zekâ ve görüntü işleme tabanlı çalışmalar gerçekleştirilmiştir. Bu sayede uzman görüşüne gerek kalmadan zeki uygulamalar ile hastalık teşhisi gerçekleştirilebilmesi hedeflenmiştir. Son yıllarda bu alanda gerçekleştirilen yapay zekâ ile tespit işlemlerinde derin öğrenme teknikleri kullanılmaktadır. Özellikle transfer öğrenme teknikleri ile model üretimi gerçekleştirilmektedir.

Chen ve arkadaşları yaptıkları çalışmada, çeltik bitkisi hastalıklarını tanımlarken kullanılan görüntülerdeki gürültü kısmının etkisini azaltmaya yönelik dikkat odaklı dinamik mod ayrıştırma tekniğini ve dört farklı çeltik bitkisi hastalık türü tespiti için XceptionNet modeli transfer öğrenme ile son katmanda makine öğrenimi algoritmaları kullanmışlardır. Çalışma sonucunda, gürültü etkisini azaltmak için geliştirdikleri algoritma ile %94,33 test başarısına ulaşmışlardır [21]. Yapılan farklı bir çalışmada ise en sık karşılaşılan Brown Spot hastalığının teşhisinde CNN-VGG19 modeli ile %93 doğruluğa küçük bir veri kümesi (40 görüntü) ile ulaşılmıştır [5]. Chowdhury ve ekibi, çalışmalarında model yorumlama ve tanımlama doğruluğunu artırmaya yönelik artık damıtılmış transformatör mimarisi kullanmışlardır. Multi-Layer Perceptron ile desteklenen mimaride dört farklı hastalık verisi için %92 oranında doğruluk değerine ulaşılmıştır. Önerilen mimari ile tahmin sonuçlarında önemli olan temel özellikleri kavramada modelin yorumlanabilmesini sağladıklarını belirtmişlerdir [22]. Bir diğer çalışmada, çeltik bitkisi hastalıklarını tespit etmek için GoogLeNet mimarisi temel alınmıştır. Mimari üzerinde evrişim çekirdek yapısı değişikliği yapılması ve mimariye dikkat mekanizması eklenmesi ile rE-GoogLeNet adı verilen mimari oluşturulmuştur. Oluşturulan bu modelin %99,58 doğruluk oranı ile GoogLeNet ile oluşturulan modelden daha başarılı sonuç verdiği gösterilmiştir [7].

Bu alanda yapılan çalışmalar temel olarak; çeltik bitkisi hastalıklarının teşhisi için kullanılan yöntem veya çalışmalarda yer verilen hastalık çeşitlerine göre gruplandırılabilir. Bu çalışmada, literatürdeki klasik makine öğrenmesi, derin öğrenme ve hibrit yöntemleri kullanan çalışmalar gruplandırma yapılarak incelenmiştir. Şekil 1'de, incelenen çalışmalardaki veri kümesi büyüklükleri ve çalışmaların başarı performans oranları grafik üzerinde verilmiştir. Şekil incelendiğinde genel olarak veri kümesi büyüklüğü arttıkça başarı değerinin arttığı gözlemlenmiştir. Genel olarak, hibrit yöntemler derin öğrenme modellerini içermektedir. Derin öğrenme metodlarının kullanıldığı çalışmalarda yüksek performans elde edildiği görülmektedir. Her hastalık için veri kümesinde yer alan örnek sayısının artmasının genel olarak başarıyı artırdığı gözlemlenmiştir. İncelenen çalışmalar arasında en çok hastalık çeşidi ile (dokuz farklı sınıf) [22] ve en az çeşit ile (bir hastalık ve sağlıklı bitki sınıf bilgisi) [2] numaralı çalışmalar öne çıkmıştır. Dört hastalık verisinin sınıflandırıldığı ve her sınıf bilgisi için en çok örnek sayısı bulduran çalışma [16] ise %99.7 oranı ile en yüksek başarıya sahip çalışmadır. Bu çalışmayı %99,58 başarı oranı ile [7] numaralı çalışma takip etmektedir. Bu çalışmada sekiz farklı hastalık verisi sınıflandırılmış ve her sınıfa ait örnek sayısı tüm incelenen çalışmaların ortalama örnek sayısından daha azdır.

Bu çalışma pirinç bitkisi hastalıklarından en sık karşılaşılan dört hastalık türü (Bacterial Blight, Blast, Brown Spot ve Tungro) üzerine yoğunlaşmıştır. Bu hastalıklardan toplamda 5932 adet örnek resim verisi bulunmaktadır. Hastalık tespiti için en uygun yöntemi bulmak amacıyla dört mimari (DenseNet, InceptionV3, VGG16 ve MobileNet) ile transfer öğrenme yaklaşımı üzerinde incelemeler gerçekleştirilmiştir.

Bu çalışma toplam dört bölümden oluşur. Birinci bölüm problem tanımı ve literatürdeki benzer problemler için üretilmiş çalışmaların özetleri ve karşılaştırmalarını sunan giriş bölümüdür. İkinci bölüm, çalışmada kullanılan veri seti ve modeller ile ilgili bilgileri içeren materyal ve metod bölümüdür. Çalışmamızda izlediğimiz süreçler bu bölümde detaylandırılmıştır. Üçüncü bölümde deneysel sonuçlarımızın tartışıldığı ve önerilen modelin sunumunu içermektedir. Son bölümde ise çalışmanın sonuç ve değerlendirmesini içerir.




Şekil 1. İncelenen çalışmalar hakkında elde edilen bilgilerin özeti
(Summary of information obtained about the studies reviewed)

2. Materyal ve Metotlar (Material and Methods)

Bu bölümde çalışmada kullanılan veri kümesi ve değerlendirme metrikleri anlatılmaktadır. Değerlendirilen metot ve elde edilen deneysel sonuçlar hakkında bilgiler de bu bölümde yer almaktadır. Çalışmada gerçekleştirilen tüm deneyler Intel(R) Core(TM) i7-8750H CPU @ 2.20GHz Windows 10 x64 işletim sistemine, Nvidia GeForce RTX 1080 Ti grafik kartına ve 16 GB RAM'e sahip bir bilgisayarda Python ile gerçekleştirildi.

Çalışmada izlenen adımlar Şekil 2'de gösterime sunulmuştur. Çalışmada kullanılan dört pirinç hastalığına ait görüntüler eğitim ve test olarak ayrılmıştır. Eğitimde kullanılacak veriler üzerinde veri çoğaltma işlemi uygulanmıştır. Artırılan eğitim verisi transfer learning metodunu kullandığımız dört farklı mimari ile modellere girdi olarak sunulmuştur. Tüm mimariler için ortak parametreler belirlenmiştir. Modellerin başarı ve kayıp değerleri ile birlikte parametre sayıları üzerinde model değerlendirme işlemleri gerçekleştirilmiştir.



Şekil 2. Çalışmada izlenen metodolojinin gösterimi
(Demonstration of the methodology followed in the study)

2.1. Veri kümesi (Dataset)

Çalışmada kullanılan veri kümesi, Mendeley'de genel kullanıma açılmış bir pirinç yaprak hastalık veri kümesidir. Toplamda "Bacterial Blight, Blast, Brown Spot ve Tungro" olarak 4 adet sınıf ve toplamda 5932 adet resim içermektedir. Veri kümesinde Bacterial Blight sınıfına ait 1584 adet, Blast sınıfına ait 1440 adet, Brown Spot için 1600 ve Tungro için toplamda 1308 adet veri bulunmaktadır. Hastalıklar yani sınıflar ile ilgili örnek görseller Şekil 3'de sunulmuştur.


Blast, patlamaya neden olur ve bir pirinç bitkisinin tüm toprak üstü kısımlarında patlama gözlemlenebilir [20]. En sık görüneni yaprak patlamasıdır. Brown Spot, yani Kahverengi Leke, en yaygın ve en zararlı pirinç hastalıklarından biridir. Bu hastalık yaprak, yaprak kılıfı ve salkım dallar üzerine bulaşabilen bir mantar

hastalığıdır [23]. Bacterial Blight hastalığında ise bakterilerden dolayı yapraklar grimsi yeşile döner ve kıvrılır. Hastalık ilerledikçe yapraklar sarararak saman rengine döner ve solgunlaşır. Bu da bütün fidelerin kurumasına ve ölmesine neden olur [30]. Tungro, viral bir hastalıktır ve yaygın olarak görünmektedir [31]. Bu çalışmada, veri kümesinde eğitim ve doğrulama için kullanılan her bir veri için veri çoğaltma işlemi gerçekleştirilmiştir. Veri çoğaltma işleminde 0.2 rotasyon uygulanmıştır. Veri çoğaltma işlemine ait görsel Şekil 4 üzerinde gösterilmektedir.

Veri kümesinde yer alan sınıflara ait sayısal bilgiler Tablo 1 üzerinde gösterilmektedir. Buna göre veri çoğaltma işlemleri ile ilgili değerler; eğitim, doğrulama ve test işlemleri için veri kümesindeki veri sayıları da tabloda görülmektedir. Toplam resim sayısı ve veri çoğaltmada kullanılan resim sayısı dört sınıf için dengeli durumdadır. Test veri sayısı olarak en fazla Brown Spot ve en az olarak Tungro sınıfları için değerlendirilmiştir.



Şekil 3. Veri kümesinde yer alan sınıflara ait örnek görüntüler
(Sample images of the classes in the dataset)



Şekil 4. Veri çoğaltma işlemi için örnek
(An example for data augmentation)

Tablo 1. Veri boyutu değişimi (Data size change)

Sınıf	Toplam resim sayısı	Veri çoğaltmada kullanılan resim sayısı	Eğitim ve doğrulamada kullanılan toplam veri sayısı	Test veri sayısı
Bacterial Blight	1584	1425	12825	159
Blast	1440	1296	11664	144
Brown Spot	1600	1440	12960	160
Tungro	1308	1177	10593	131
Toplam	5932	5338	48042	594

2.2. Değerlendirme metrikleri (Evaluation metrics)

Literatürde makine öğrenmesi algoritmalarında model performansının değerlendirmesinde doğruluk (accuracy), duyarlılık (recall), kesinlik (precision) ve F-ölçütü (F1-score) sık kullanılan metriklerdir. Bu metrikler sınıflandırma sonucunda elde edilen hata matrisi kullanılarak çözümlenmektedir. Hata matrisinde, gerçek ve tahmin sınıfları için pozitif ve negatif etiketler bulunmaktadır. Gerçek sınıfta pozitif etikete sahip verilerin; tahmin sınıfında pozitif etikete sahip olması Doğru Pozitif (DP), tahmin sınıfında negatif etikete sahip olması ise Yanlış Negatif (YN) ile ifade edilir. Gerçek sınıfta negatif etikete sahip verilerin; tahmin sınıfında pozitif etikete sahip olması Yanlış Pozitif (YP), tahmin sınıfında negatif etikete sahip olması ise Doğru Negatif (DN) ile ifade edilir. Eşitlik 1 üzerinde doğruluk değerinin matematiksel gösterimi ve kullanılan değerler yer almaktadır.

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

2.3. Metotlar (Methods)

Çalışmada problemin çözülmesine yönelik dört adet derin öğrenme mimarisi ile modeller geliştirilmiştir. Buradaki amaç problem çözümü için en uygun modelin belirlenmesidir. Bu mimariler DenseNet, InceptionV3, VGG16 ve MobileNet'tir. DenseNet, özellik haritalarını ağ boyunca bir katmandan diğerine yinelemeli olarak birleştiren bir mimari sunmaktadır [27]. InceptionV3 ise Google tarafından geliştirilmiştir ve serisinin üçüncü sürümüdür. Model ağı en iyi hale getirmek üzere bir dizi yaklaşım kullandığı için eğitilmesi zaman bakımından maliyetli olan bir mimaridir [28]. VGG16, Görsel Geometri Grubu (Visual Geometry Group, VGG) tarafından geliştirilen evrişimli bir sinir ağı modelidir. Model

performansını yüksek boyutlu evrişim çekirdekleri (11×11 , 7×7) yerine birden fazla 3×3 boyutunda evrişim çekirdeğinin kullanılması ile artacağı düşüncesi ile geliştirilmiş bir mimaridir [25]. MobileNet ise model boyutu daha küçük, eğitilebilir parametreleri ve hesaplama miktarı daha az olan ve kısıtlı olarak mobil cihazlarda dağıtım için uygun hale getirilen bir mimaridir [26].

Tablo 2. Modellerdeki parametre değerleri (Parameter values in models)

Parametre	Değer
Tek seferde alınan örnek sayısı boyutu	32
Öğrenme oranı	$1e-4$
Optimizasyon algoritması	optimizers.SGD
Başlangıç ağırlık değerleri	Imagenet
Momentum	0.9
Kayıp fonksiyonu	categorical_crossentropy
Son katman	Softmax
Epok	50
Tek seferde alınan örnek sayısı boyutu	32
Öğrenme oranı	$1e-4$
Optimizasyon algoritması	optimizers.SGD

Bu çalışmada dört mimari içinde transfer öğrenme yaklaşımı kullanılmıştır. Transfer öğrenimi; farklı bir modelin daha büyük veya farklı bir veri kümesi üzerinde eğitilmesiyle elde edilen ağırlıkları kullanarak bir modeli önceden başlatma işlemidir [29, 32]. Derin öğrenme modelini küçük bir veri kümesiyle eğitmek genellikle modelin performansı açısından yetersizdir. Bu sorunun önüne geçmek için transfer öğrenimi yöntemi kullanılır. Bu yöntem ile derin öğrenme sürecindeki ilk birkaç katman, görevin özelliklerini tanımlamak için eğitilir. Eğitilen ağırlık son birkaç katmanı kaldırılabilir ve hedef görev için yeni katmanlarla yeniden eğitilebilir. Çalışmada son katman, problem sınıfı sayısına göre şekillendirilmiştir.

Tüm model geliştirmelerinde kullanılan parametreler sabit tutulmuştur. Bu parametreler ve ilgili değerler Tablo 2’de verilmiştir.

3. Deneysel Sonuçlar (Experimental Results)

Çalışmada dört pirinç bitkisi hastalığı için geliştirilen modellerde elde edilen eğitim ve test başarı değerleri Tablo 3 üzerine yerleştirilmiştir.

Tablo 3. Modellerin başarı değerleri (Success values of the models)

Model	Eğitim Başarısı	Eğitim Kayıp	Test Başarısı	Test Kayıp	Parametre Sayısı
DenseNet	0.9989	0.0075	1.0	0.0019	18,329,668
InceptionV3	0.9985	0.0079	1.0	0.0014	21,810,980
VGG16	1.0	0.0005	1.0	0.0001	14,716,740
MobileNet	0.8933	0.2809	0.9356	0.1410	2,263,108

Başarı değerleri incelendiğinde eğitim ve test verisi üzerindeki en yüksek başarı değeri VGG16 ile elde edilmiştir. Eğitilen modeller arasında en düşük başarı değeri ise MobileNet ile oluşturulan modelde gözlemlenmiştir. VGG16 modelinin yüksek doğruluk, düşük kayıp değerleri üretmesi ve aynı zamanda dört modelden düşük parametre sayısında ikinci sırada olması modelin tercih edilebilirliğini artırmıştır.

MobileNet ile oluşturulan model hariç diğer tüm modellerde, literatürde incelenen çalışmalardan daha başarılı sonuç üretilmiştir. Özellikler aynı veri seti veya aynı sınıf sayısına sahip çalışmalar karşılaştırıldığında [2,9,12,13,15,16,17,19] en başarılı model VGG16 ile çalışmada üretilen modeldir. Upadhyay ve Kumar 2021’de gerçekleştirdikleri çalışmada %99,7 ile çalışmamıza en yakın sonuçları elde etmişlerdir.

4. Sonuç ve Değerlendirme (Conclusion and Evaluation)

Hastalık belirtileri bitkilerin çeşitli kısımlarında görülebilir. Özellikle yapraklar bitki hastalığını teşhis etmek için yaygın olarak kullanılmaktadır. Derin öğrenme uygulamalarının gelişmesi, araştırmacıları yaprak görüntüsü analiz tekniklerini kullanarak bitki hastalıklarını tanıma konusunda araştırma yapmaya teşvik etmektedir. Son yıllarda bu alanda yapılan çalışma sayısı artış göstermektedir. Bu çalışmada, çeltik bitkisi hastalığı transfer öğrenme tekniği ile üretilen model sayesinde tahmin edilmektedir. Çalışmada kullanılan erişime açık veri kümesinde, toplamda dört hastalık görüntüsü bulunmaktadır. Yüksek doğruluk sağlama, düşük kayıp değerler üretmesi ve aynı zamanda düşük parametre sayısına sahip olması ile VGG16 modeli çalışmada seçilmiştir. Önerilen çalışmadan elde edilen sonuçlar, çeltik bitkisi hastalıklarının teşhis edilmesi

konusunda oldukça umut vericidir. Ama çalışmada en yaygın görülen dört hastalık verisi kullanılsa da farklı hastalıklar da mevcuttur. İleriki çalışmalar için hastalık çeşidini artırmak ve gerçek zamanlı tanıma sistemi oluşturarak çiftçiye katkılar sağlamak amaçlanmaktadır.

Teşekkür (Acknowledgment)

Çalışma FGA-2022-7973 nolu Gazi Üniversitesi BAP Projesi tarafından desteklenmiştir. Destekleri için Gazi Üniversitesine teşekkür ederiz.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] M. Shahbandeh, "Grain production worldwide 2022/23, by type," Sept. 20, 2023. [Online]. Available: <https://www.statista.com/statistics/263977/world-grain-production-by-type/>. [Accessed: Nov. 10, 2023]
- [2] N. Krishnamoorthy, L.V.N. Prasad, C.S.P. Kumar, B. Subedi, H.B. Abraha and V.E. Sathishkumar, "Rice leaf diseases prediction using deep neural networks with transfer learning," *Environmental Research*, Vol. 198, pp. 1-8, 2021. doi: 10.1016/j.envres.2021.111275.
- [3] O. Wallach, "Visualizing the World's Biggest Rice Producers," Feb. 23, 2022. [Online]. Available: <https://www.visualcapitalist.com/worlds-biggest-rice-producers/>. [Accessed: Nov. 10, 2023]
- [4] K. M. Sudhesh, , V. Sowmya, , S. Kurian and O. K. Sikha, "AI based rice leaf disease identification enhanced by Dynamic Mode Decomposition," *Engineering Applications of Artificial Intelligence*, Vol. 120, pp. 1-22, 2023. doi: 10.1016/j.engappai.2023.105836.
- [5] R. Dogra, S. Rani, A. Singh, M. A. Albahar, A. E. Barrera and A. Alkhayat, "Deep learning model for detection of brown spot rice leaf disease with smart agriculture," *Computers and Electrical Engineering*, Vol. 109, pp. 1-11, 2023. doi: 10.1016/j.compeleceng.2023.108659.
- [6] C. Zhou, Y. Zhong, S. Zhou, J. Song and W. Xiang, "Rice leaf disease identification by residual-distilled transformer," *Engineering Applications of Artificial Intelligence*. Vol. 121, pp. 1-9, 2023. doi: 10.1016/j.engappai.2023.106020.
- [7] L. Yang, X. Yu, S. Zhang, H. Long, H. Zhang, S. Xu and Y. Liao, "GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases," *Computers and Electronics in Agriculture*, Vol. 204, pp. 1-11, 2023. doi: 10.1016/j.compag.2022.107543.
- [8] T. G. Devi and P. Neelamegam, "Image processing based rice plant leaves diseases in Thanjavur, Tamilnadu," *Cluster Computing*, Vol. 22, pp. 13415–13428, 2019. doi: 10.1007/s10586-018-1949-x.
- [9] M. Al-Amin, D. Z. Karim and T. A. Bushra, "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 2019, Dhaka, Bangladesh, 18-20 December 2019*, pp. 1–5,
- [10] M. E. Pothan and M. L. Pai, "Detection of Rice Leaf Diseases Using Image Processing," in *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, pp. 424-430, 2020. doi: 10.1109/ICCMC48092.2020.ICCMC-00080.
- [11] S. Ramesh and D. Vydeki, "Recognition and classification of paddy leaf diseases using Optimized Deep Neural network with Jaya algorithm," *Information Processing in Agriculture*, Vol. 7, 2020, pp. 249-260, doi: 10.1016/j.inpa.2019.09.002.
- [12] S. Ghosal and K. Sarkar, "Rice Leaf Diseases Classification Using CNN With Transfer Learning," in *2020 IEEE Calcutta Conference, CALCON 2020, Kolkata, India, 28-29 February 2020*, pp. 230-236.
- [13] B.S. Bari, M.N. Islam, M.M. Rashid, M.J. Hasan, M.A. Razman, R.M. Musa, A.F. Nasir and A.P. Majeed, "A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework," *PeerJ Computer Science*, Vol. 7, pp. 1-27, 2021. doi: 10.7717/peerj-cs.432.
- [14] P. Mekha and N. Teeyasuksaet, "Image Classification of Rice Leaf Diseases Using Random Forest Algorithm," in *2021 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering, Cha-am, Thailand, 03-06 March 2021*, pp. 165-169,
- [15] S. M. Shahidur Harun Romy, M. I. Arefin Hossain, F. Jahan and T. Tanvin, "An IoT based System with Edge Intelligence for Rice Leaf Disease Detection using Machine Learning," in *2021 IEEE International IOT, Electronics and Mechatronics Conference IEMTRONICS 2021, Toronto, ON, Canada, 21-24 April 2021*, pp. 1-6,
- [16] S.K. Upadhyay and A. Kumar, "A novel approach for rice plant diseases classification with deep convolutional neural network" *International Journal of Information Technology*, Vol. 14, pp. 185–199, 2022. doi: 10.1007/s41870-021-00817-5.

- [17] P. K. Sathy, N. K. Barpanda, A. K. Rath and S. K. Behera, "Deep feature based rice leaf disease identification using support vector machine", *Computers and Electronics in Agriculture*, Vol. 175, pp. 1-9, 2020. doi: 10.1016/j.compag.2020.105527.
- [18] Z. Jiang, Z. Dong, W. Jiang and Y. Yang, "Recognition of rice leaf diseases and wheat leaf diseases based on multi-task deep transfer learning", *Computers and Electronics in Agriculture*, Vol. 186, pp. 1-9, 2021. doi: 10.1016/j.compag.2021.106184.
- [19] F. Jiang, Y. Lu, Y. Chen, D. Cai and G. Li, "Image recognition of four rice leaf diseases based on deep learning and support vector machine", *Computers and Electronics in Agriculture*, Vol. 179, pp. 1-9, 2020, doi: 10.1016/j.compag.2020.105824.
- [20] A. Sparks, "blast leaf collar" Sept. 10, 2021. [Online]. Available: <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/blast-leaf-collar>. [Accessed: Nov. 10, 2023]
- [21] J. Chen, D. Zhang, Y. A. Nanekharan and D. Li, "Detection of rice plant diseases based on deep transfer learning," *Journal of the Science of Food and Agriculture*, Vol. 100, pp. 3246-3256, 2020. doi: 10.1002/jsfa.10365.
- [22] C.R. Rahman, P.S. Arko, M. E. Ali, M. A. I. Khan, S. H. Apon, F. Nowrin and A. Wasif, "Identification and recognition of rice diseases and pests using convolutional neural networks," *Biosystems Engineering*, Vol. 194, pp. 112-120, 2020. doi: 10.1016/j.biosystemseng.2020.03.020.
- [23] A. Sparks, "Brown Spot" Sept. 15, 2021. [Online]. Available: <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/brown-spot>. [Accessed: Nov. 10, 2023]
- [24] M. T. Ahad, Y. Li, B. Song and T. Bhuiyan, "Comparison of CNN-based deep learning architectures for rice diseases classification," *Artificial Intelligence in Agriculture*, Vol. 9, pp. 22-35, 2023. doi: 10.1016/j.aiaa.2023.07.001.
- [25] H. Yang, J. Ni, J. Gao, Z. Han and T. Luan, "A novel method for peanut variety identification and classification by Improved VGG16," *Scientific Reports*, Vol. 11, pp. 1-17, 2021. doi: 10.1038/s41598-021-95240-y.
- [26] Y. Nan, J. Ju, Q. Hua, H. Zhang and B. Wang, "A-MobileNet: An approach of facial expression recognition," *Alexandria Engineering Journal*, Vol. 61, pp. 4435-4444, 2022. doi: 10.1016/j.aej.2021.09.066.
- [27] X. Xu, J. Lin, Y. Tao and X. Wang, "An improved DenseNet method based on transfer learning for fundus medical images," in *7th international conference on digital home 2018 (ICDH)*, pp. 137-140. Nov. 30 - Dec 01, 2018, Guilin, China [Online]. Available: IEEE Xplore, <http://www.ieee.org>. [Accessed: 10 Nov. 2023].
- [28] M. Mujahid, F. Rustam, R. Álvarez, J. L.V. Mazón, I. T. Díez and I. Ashraf, "Pneumonia classification from X-ray images with inception-V3 and convolutional neural network," *Diagnostics*, Vol. 12, pp. 1-16, 2022. doi: 10.3390/diagnostics12051280.
- [29] K. Weiss, T. M. Khoshgoftaar and D. Wang, "A survey of transfer learning," *Journal of Big data*, Vol. 3, pp. 1-40, 2016. doi: 10.1186/s40537-016-0043-6.
- [30] A. Sparks, "Bacterial Blight" Sept. 25, 2021. [Online]. Available: http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/diseases/item/bacterial-blight?category_id=326. [Accessed: Nov. 10, 2023]
- [31] N. A. Mohamed, N. M. F. Ngah, A. Abas, N. Talip, M. N. Sarian, H. S. Hamezah, S. Harun and H. Gunawan, "Candidate miRNAs from *Oryza sativa* for Silencing the Rice Tungro Viruses," *Agriculture*, Vol. 13, pp. 1-14, 2023. doi: 10.3390/agriculture13030651.
- [32] N. Barışçı, M. Güllü and İ.A. Doğru, "Derin Transfer Öğrenmeye Dayalı Pirinç Bitkisi Hastalıklarının Tespiti," in *Accepted Abstracts e-Book: Proc. of the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering, ICAIAME 2023, Antalya, Türkiye, 03-05 November 2023*, pp. 40.

* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license

