

BİLGİSAYAR DESTEKLİ TANI YAKLAŞIMLARININ PERFORMANS DEĞERLENDİRMESİ: GELENEKSEL MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME

Musa ÇETİNKAYA

Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Bilecik, Türkiye

ORCID ID: 0009-0007-4736-4441

Doç. Dr. Ümit Çiğdem TURHAL

Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Devreler ve Sistemler Anabilim Dalı, Bilecik, Türkiye

ORCID ID: 0000-0003-2387-1637

ÖZET

Geleneksel makine öğrenmesi (TML) ve derin öğrenme (DL), yapay zeka alanında iki önemli yaklaşımdır. TML, tahmine dayalı modeller oluşturmak için karar ağaçları, destek vektör makineleri (SVM), k-en yakın komşular (k-NN) gibi çeşitli algoritmalar kullanır. Bu yaklaşımda özellik çıkartımı algoritmanın başarımını etkileyen en önemli unsurdur. TML küçük veri kümelerinde başarılı sonuçlar elde ederken karmaşık veriler ve büyük ölçekli veri kümelerinde aynı başarıyı gösteremezler. Makine öğreniminin bir alt kümesi olan DL ise ham veriden hiyerarşik özellik temsillerini otomatik olarak öğrenmek için çok katmanlı sinir ağlarını kullanır. Görüntü tanıma, doğal dil işleme ve konuşma tanıma gibi çalışmalarda çok iyi sonuçlar elde ederken büyük miktarda veri ve hesaplama kaynağı gerektirir. Bu çalışma TML ve DL'nin tahmin performansını karşılaştırmak amacıyla bitki hastalığının bilgisayar destekli teşhisini sunmaktadır. Bitki hastalıklarının tespiti, modern tarımda ürün kayıplarını en aza indirmek ve gıda güvenliğini sağlamak açısından çok önemlidir. Bitki hastalıklarının erken ve doğru bir şekilde belirlenmesi pestisit kullanımını azaltabilir, mahsul verimini artırabilir ve ürün kalitesini iyileştirebilir. Bu amaçla çalışmada geleneksel yöntemlerden lojistik regresyon (LR), destek vektör makineleri (SVM), ve rastgele orman algoritmaları (RF) ile derin öğrenme yöntemlerinden konvolüsyonel sinir ağı (CNN), LSTM, YOLOv8 ve VGG16 algoritmalarının performansları karşılaştırılmıştır. Elde edilen sonuçlar TML'de SVM için %78.6 ile en yüksek olmak üzere ortalama %78.8 elde edilirken DL'de CNN için %99 ile en yüksek olmak üzere ortalama %91.75 olacak şekilde elde edilmiştir.

Anahtar Kelimeler: Yapay zeka, makine öğrenmesi algoritmaları, özellik çıkartımı, derin öğrenme

PERFORMANCE EVALUATION OF COMPUTER-AIDED DIAGNOSIS APPROACHES: TRADITIONAL METHODS AND DEEP LEARNING TECHNIQUES

ABSTRACT

Traditional machine learning (TML) and deeplearning (DL) are two important approaches in artificial intelligence. To build predictive models, TML uses algorithm ssuch as decision trees, support vector machines (SVM), and k-nearest neighbors (k-NN). In this approach, feature extraction is the most important element affect in the performance of the algorithm. While TML achieves successful results in small datasets, it cannot show the same success in complex data and large-scale data sets. DL, a subset of machine learning, uses multilayer neural networks to automatically learn hierarchical feature representations from rawdata. While it achieves very good results in studies such as image recognition, natural language processing and speech recognition, it requires large amounts of data and computational resources. This study presents computer-aided diagnosis of plant disease to compare the predictive performance of TML and DL. Plants are a source of food and life of great importance for humans and other living things. Detection of plant diseases is very important in modern agriculture to minimize product losses and ensure food safety. Early and accurate identification of plant diseases can reduce pesticide use, increase crop yields and improve product quality. For this purpose, the performance of traditional methods such as logistic regression (LR), support vector machines (SVM), and random forest algorithms (RF) and deep learning methods such as convolutional neural network (CNN), LSTM, YOLOv8 and VGG16 algorithms were compared. The results obtained were obtained as an average of 78.8%, with the highest being 78.6% for SVM in TML, and an average of 91.75%, with the highest being 99% for CNN in DL.

Keywords: Artificial intelligence, machine learning algorithms, feature extraction, deep learning

1.GİRİŞ

Dijital görüntü çok miktarda bilgi içerir. Bilginin hayati önem taşıdığı çağımızda, faydalı görsel bilgiye etkili bir şekilde ulaşabilmek birçok sorunun çözümünde kritik rol oynuyor. Görsel bilginin çıkarılması, çeşitli görüntü işleme yöntemlerini ve sınıflandırma, kümeleme gibi yapay zeka uygulamalarını içerir. Görüntü sınıflandırma her zaman önemli bir araştırma alanı olmuştur ve makine öğrenimi algoritmaları bu amaç için yaygın olarak kullanılmaktadır. Makine öğreniminin bir dalı olarak derin öğrenme ise güçlü performansı ile son yıllarda bu alanda öne çıkmıştır.

Farklı modellerin farklı problemler üzerinde farklı etkileri vardır. Bu nedenle, geleneksel makine öğrenimi (TML) ile derin öğrenme (DL) tabanlı görüntü sınıflandırma algoritmalarının karşılaştırılması ve analiz edilmesi, görüntülerin sınıflandırılması için en uygun algoritmaların seçilmesi açısından önemlidir.(Zhao, 2018; Wang, 2017).

Modern yapay zeka teknolojilerinin gelişimini ve uygulamalarını daha iyi anlamak için TML ile DL arasındaki farkları anlamak önemlidir. Makine öğrenimi, verilerden öğrenerek belirli görevleri otomatikleştiren algoritmaların geliştirilmesidir. TML yöntemleri, manüel özellik çıkarma ve seçimini içerir ve bu süreçte insan uzmanlığı çok önemlidir. Bu yöntemler tipik olarak lojistik regresyon (LR), karar ağaçları (DT) ve destek vektör makineleri (SVM) vb. algoritmaları kullanır ve daha küçük ve yapılandırılmış veri kümeleriyle kullanılır (Juan, 2016; Nguyen, 2016). DL, büyük ve karmaşık veri kümelerinden değerli bilgileri otomatik olarak çıkarmak için sinir ağı mimarisini kullanan bir makine öğrenimi alt kümesidir. DL algoritmaları özellikle görüntü tanıma, doğal dil işleme ve ses tanıma gibi görevlerde başarılı olmuştur. Bu algoritmalar, yapay sinir ağlarının organize katmanlarını kullanarak ham verilerden özellikler öğrenebilir ve çıkarabilir. DL'nin, büyük veri kümeleri ve önemli bilgi işlem kaynakları içeren uygulamalarda oldukça etkili olduğu kanıtlanmıştır. Bu makale, en uygun görüntü sınıflandırma algoritmasının seçilmesinde rehberlik sağlamak amacıyla popüler makine öğrenmesi yöntemlerinden lojistik regresyon (LR), destek vektör makinesi (SVM) ve rastgele orman (RF) algoritmaları ile popüler derin öğrenme yöntemlerinden LSTM, VGG16, YOLOv8 ve CNN algoritmalarının performanslarını karşılaştırılmıştır. Performans karşılaştırması, yaprak görüntüleri üzerinden bitki hastalıklarının teşhisi şeklinde gerçekleştirilmiş olup elde edilen sonuçlar karşılaştırmalı olarak verilmiştir.

Tarım alanındaki bitkiler sadece besin kaynağı değil ülkelerin finansal getirilerini de etkilemektedir. Bu getirilerin artması bitkiden elde edilen besinlerin sağlıklı olması, dolaylı olarak bitkilerin sağlıklı olmasıyla orantılıdır (Doğan, 2019; Ecemiş, 2022). Canlılar için önem arz eden bu yaşam kaynaklarının hastalıklardan korunmasını sağlamak gerekir. Hastalık fark etmeksizin bu işlemin yapılması gerekir çünkü bitki için her türlü olumsuz durumun önceden tespiti zamanında önlem almayı kolaylaştırır. Bu konu hakkında literatürde TML yöntemlerinin (Kumar et al. 2020; Yin&Nay, 2018) ve DL yöntemlerinin (Gharpankar, 2020; Long, 2018) kullanıldığı çeşitli çalışmalar bulunmaktadır.

2. MATERYAL VE YÖNTEM

2.1 Materyal

Çalışma için Kaggle’da bulunan New Plant Diseases Dataset’i kullanılmıştır. Veri seti, 38 farklı bitki türünden sağlıklı ve hastalıklı yaprakların yaklaşık 87.000 renkli görüntüsünü içermektedir. Veri setindeki görseller 256x256 piksel çözünürlüğe sahiptir. Veri setindeki yaprakların adları Tablo 1 ve görüntüleri Şekil 1’de verildiği gibidir.

Tablo 1. Veri setinden alınan rastgele yaprak türü isimleri

No	Yaprak Türleri	No	Yaprak Türleri
1	Apple___Apple_scab	6	Peach___healthy
2	Cherry_(including_sour)___healthy	7	Potato___Early_blight
3	Corn_(maize)___healthy	8	Raspberry___healthy
4	Grape___Black_rot	9	Tomato___Bacterial_spot
5	Peach___Bacterial_spot	10	Tomato___Tomato_mosaic_virus




Şekil 1. Veri setinden alınan rastgele yaprak türü görüntüleri

2.2 Yöntem

Çalışma, Google Colab ortamında Python yazılım dili kullanılarak elde edilmiştir. Çalışmada bir Python Kütüphanesi olan scikit-learn kütüphanesindeki geleneksel modellerden LR, SVM, RF ile DL modellerinden LSTM ile keras kütüphanesinden VGG16, YOLOv8 ve CNN ayrıca görüntü işleme için önceden eğitilmiş ImageNet ağırlıklarından, yararlanılmıştır. Aşağıdaki bölümlerde çalışmada kullanılan görüntü işleme adımları ve TML algoritmaları ile DL algoritmalarının kısa açıklamaları yer almaktadır.

2.2.1 Görüntü işleme yöntemleri

Karar ağaçları(DT), SVM, k-NN gibi birçok makine öğrenmesi modeli sınıflandırma işlemlerinde kullanılmaktadır. Görüntülerin özellikleri olarak renk, şekil, doku bilgisi, eğitim ve test işlemlerinde en iyi performans olarak kullanılmaktadır. Renk özellikleri olarak kırmızı, yeşil, mavi(RGB) ve renk, doygunluk, değer(HSV) verilebilir. Doku özellikleri olarak gri düzey eş oluşum matrisleri(GLCM) ve yönlü gradyanlar histogramı(HOG) verilebilir.



Şekil 2. a)Orijinal Görüntü, b)HSV Görüntüsü, c)Gri Görüntüsü, d)Binary Görüntüsü, e)Yönlü Gradyanlar Histogramı

2.2.2 TML Algoritmaları

Lojistik Regresyon(LR): İsminde regresyon geçmesine rağmen bir sınıflandırma algoritmasıdır. Amacı bağımlı değişkenler ile bağımsız değişkenler arasındaki olasılıkları tahmin ederek bir ilişki kurmaya yardımcı olan lojik fonksiyonunu kullanır. Bu fonksiyon olasılıkları ikili (binary) değerlere dönüştürerek tahminde kullanır.

Destek Vektör Makineleri(SVM):Vektörler yardımı ile etiketlenmiş verileri birbirinden ayırır. Karar sınırı (decision boundary) ile sınıflar arasındaki en iyi boşluğu (margin) bularak vektörü (hyperplane) çeker.

Rastgele Orman(RF):Rastgele orman veya rassal orman birden fazla karar ağacı algoritmasını birleştiren bir makine öğrenmesi algoritmasıdır. Her karar ağacından gelen veriler ile tahminlerin çoğunluk oyuna dayanarak nihai çıktıyı verir.

2.2.3 DL Algoritmaları

Uzun-Kısa Vadeli Bellek(LSTM): Özyinelemeli Sinir Ağı(RNN)'de bir önceki adımın çıkışı bir sonraki adımın girişi olarak kullanılır. RNN'deki kısa vadeli hafızaya çözüm olarak LSTM kullanılmıştır. İçerisindeki özel hücre yapıları (Forgetgate, inputgate, outputgate ve cellstate) ile veriyi uzun süre hafızada tutar. RNN veri dizilerindeki gradyanların kaybolması konusuna çözüm olmuştur.

VGG16: VGG16, bilgisayarlı görme modellerinden biri olan evrişimli sinir ağı(CNN) türüdür. 13 evrişimsel katmana, 5 max pooling katmanına ve 3 dense katmanına sahiptir. Öğrenme katmanları 16 olduğu için denilmiştir.

YOLOv8: YOLOv8, giriş görüntüsünü ızgaralara böler ve her bölünen hücre kendi hücrelerinde nesne tespitinden sorumludur. Bu hücreler içinde nesnelere işaretler ve her nesne için güven skorunu tahmin eder. Her hücreden özellikler çıkarır ve uygun biçimde birleştirir. Bu çıkarılan güven skorları farklı amaçlarda kullanılır.

Evrişimsel Sinir Ağı(CNN): CNN'ler, bir giriş görüntüsüne veya videoya bir dizi evrişim ve havuz katmanları(pooling layers) uygulayarak çalışır. Evrişim katmanları, küçük bir filtreyi görüntü veya video üzerinde kaydırarak filtre ile giriş arasındaki nokta çarpımı hesaplayarak girişten özellikler çıkarır.

3. DENEYSEL ÇALIŞMALAR ve BULGULAR

Bu çalışmadan makine öğrenmesi ve derin öğrenmesi algoritması olmak üzere toplamda 7 model kullanılmıştır. Bu modeller Google Colab üzerinde Python yazılım diliyle yazılmıştır. Çalışma 3 ana bölümden oluşmaktadır: Veri setinin toplanması, görüntü işleme adımları, özellik çıkarımı ve sınıflandırma.

3.1 Veri Setinin Toplanması: Veri seti Kaggle'da bulunan 38 farklı hastalıklı ve sağlıklı yaprak görüntülerinden oluşuyor. Çalışmadan kullanılan veri seti %80 eğitim seti, %20 doğrulama seti olarak ayrılmıştır. Toplamda 87.000 renkli görüntü içermektedir.

3.2 Görüntü İşleme Adımları: Görüntülerin sınıflandırma modellerine uygun hale getirilmesi için ön işleme aşamaları uygulanır. Yeniden boyutlandırılmasının nedeni modellerin hızlı çalışması, işlem süresinin azaltılmasıdır. Bu nedenle görüntüler 256x256 piksel olarak yeniden boyutlandırılmıştır. Görüntü işlemlerinde kullanılan diğer işlemler Şekil.2'de verilmiştir.

3.3 Sınıflandırma: Sınıflandırma aşamasında diğer aşamalarda yapılan işlemler bir araya getirilmiştir ve model üzerinde sonuçlar gözlemlenmiştir. Çıktı sonuçları Tablo 2'de verilmiştir.

Tablo 2. Çalışma sonuçlarının doğruluk yüzdeleri verilmiştir

No	Sınıflandırma Çeşidi	Sınıflandırma Modelleri	Doğruluk(%)
1	TML	Lojistik Regresyon(LR)	79,7
2		Destek Vektör Makineleri(SVM)	78,6
3		Rastgele Orman(RF)	78
4	DL	Uzun-Kısa Vadeli Bellek(LSTM)	81,9
5		VGG16	88
6		YOLOv8	98,3
7		CNN	99,02

4. SONUÇLAR

Bu çalışma TML ve DL'nin tahmin performansını karşılaştırmak amacıyla bitki hastalığının bilgisayar destekli teşhisini sunmaktadır. Lojistik Regresyon, Destek Vektör Makineleri, Rastgele Orman, Uzun-Kısa Vadeli Bellek, VGG16, YOLOv8 ve CNN modelleri kullanılmıştır. Tablo 2’de görüldüğü üzere en yüksek sonuç CNN’de görülmüştür. TML’de görüntülerde bilgi çıkarımı lineer regresyon, ağaç tabanlı modeller ile yapılırken, DL yapay sinir ağlarını kullanır. DL daha az insan müdahalesine ihtiyaç duyar. Genel sonuca bakıldığında DL modelleri TML modellerine göre daha başarılı olmuştur.

5. KAYNAKÇA

Juan, W., Xianxiang, W., & Yanling, C. (2016). Image classification algorithm based on bbo-mlp and texture features [J]. *Optoelectronic laser*, 11, 1214-1219.

Nguyen, L. A. T. (2016). Traffic Image Classification using Horizontal Slice Algorithm. *International Journal of Computer Applications*, 975, 8887.

Zhao, L., Zhang, W., Sun, Z. G., & Chen, Q. (2018). Brake pad image classification algorithm based on color segmentation and information entropy weighted feature matching. *Journal of Tsinghua University (Science and Technology)*, 58(6), 547-552.

<http://dx.doi.org/10.3969/j.issn.1673-3193.2017.02.018> (son erişim tarihi: 10.07.2024)

Doğan, M.S. 2019. Bitkilerde görülen hastalıkların derin öğrenme yöntemleriyle tespiti ve sınıflandırılması. Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Mühendisliği Bilim Dalı, Yüksek Lisans Tezi.

Ecemiş, İ.N. 2022. Derin öğrenme teknikleri kullanılarak bitki yaprağı görüntüleri üzerinden tür ve olası hastalık tespiti. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Mühendisliği Bilim Dalı, Yüksek Lisans Tezi.

<https://doi.org/10.22214/ijraset.2020.32205> (son erişim tarihi: 11.07.2024)

<https://doi.org/10.1109/ICSTCEE49637.2020.9277379> (son erişim tarihi: 12.07.2024)

Oo, Y. M., & Htun, N. C. (2018). Plant leaf disease detection and classification using image processing. *International Journal of Research and Engineering*, 5(9), 516-523.

Long, M., Ouyang, C., Liu, H., & Fu, Q. (2018). Image recognition of *Camellia oleifera* diseases based on convolutional neural network & transfer learning. *Transactions of the Chinese Society of Agricultural Engineering*, 34(18), 194-201.

Kaggle, <https://www.kaggle.com/datasets/vipooool/new-plant-diseases-dataset> (son erişim tarihi: 8.07.2024)