



Yapay Sinir Ağları ile Mısır Yapraklarında Hastalık Tespiti

Resul BÜTÜNER^{a,*}, Muzaffer ŞİMŞEK^b, Gökhan AKSÖZ^c,

Sadi ŞAN^d

^{a*, b, c, d} Beypazarı Fatih M.T.A.L., Ankara, 06730 TÜRKİYE

MAKALE BİLGİSİ

Alınma: 02.11.2023
Kabul : 26.12.2023

Anahtar Kelimeler:

Yapay zekâ, Yapay sinir ağı, Mısır, Mısır hastalığı, Tespit etme, Mısır yaprağı
***Sorumlu Yazar**
e-posta:
rbutuner@gmail.com

ÖZET

Mısır, tarihte yaklaşık 10.000 yıl önce güney Meksika'daki yerli halklar tarafından evcilleştirilen ve günümüzde dünya genelinde popüler bir gıda maddesi olarak kabul edilen bir tahıl çeşididir. Dünya nüfusunun artmasıyla birlikte, diğer birçok besin maddesinde olduğu gibi mısır tüketiminde de belirgin bir artış gözlenmektedir. Ancak, bu önemli ürünün üretiminde meydana gelen hastalıklar, özellikle yoğun tüketim yaşanan ülkeler için ciddi bir sorun oluşturabilir. Mısır üreticileri, olası hastalıkları belirlemek ve izlemek konusunda sürekli bir takip içerisindeyler. Ne var ki, modern teknoloji mısır hastalıklarının tespiti ve izlenmesi için tam anlamıyla kullanılamamaktadır. Geleneksel tespit yöntemlerinin yanı sıra Yapay Zekâ, Görüntü İşleme, Yapay Sinir Ağları, ve Derin Öğrenme gibi yeni teknolojiler, hastalıkların tespiti için kullanılmaktadır. Bu yöntemler ve teknikler, hastalıkların etkili ve hızlı bir şekilde teşhis edilmesine ve gereken müdahalelerin teknolojik çözümlerle yapılmasına olanak tanımaktadır. Bu araştırmada, dört farklı mısır hastalığı ve sağlıklı mısır görüntüleri toplanmış ve bu görüntülerin analizinde K-En Yakın Komşu Algoritması, Rastgele Orman Algoritması ve Yapay Sinir Ağları kullanılmıştır. Bu algoritmalar, yapay zekâyı eğitmiş ve öğrenmiş modeller ortaya koymuştur. Eğitim süreci sonucunda model oluşturulmuş ve sağlıklı mısır, mısır pası, yaprak lekesi ve yaprak yanığı görüntüleriyle karşılaştırılmıştır. Mısır yaprağı hastalığı tespitinde elde edilen başarı oranları şu şekildedir: K-En Yakın Komşu Algoritması %97, Rastgele Orman Algoritması %97,6 ve Yapay Sinir Ağları %97,7. Bu sonuçlar doğrultusunda, oluşturulan Yapay Sinir Ağı modelinin yüksek doğruluk oranıyla mısır hastalıklarının tespiti için kullanılabileceği ve gelecekte yapılacak çalışmalara rehberlik edebileceği öngörülmektedir.

DOI: 10.59940/jismar.1384930

Disease Detection in Corn Leaves with Artificial Neural Networks

ARTICLE INFO

Received: 02.11.2023
Accepted: 26.12.2023

Keywords:

Artificial intelligence, Artificial neural network, Corn, Corn disease, Detection, Corn leaf
***Corresponding Authors**
e-mail:
rbutuner@gmail.com

ABSTRACT

Corn, a grain variety domesticated by indigenous peoples in southern Mexico around 10,000 years ago, is considered a popular food globally today. With the increase in the world's population, there has been a significant rise in corn consumption, as observed in many other food items. However, diseases affecting the production of this crucial crop could pose a serious problem, especially in countries with high consumption rates. Corn producers remain continuously vigilant in identifying and monitoring potential diseases. However, current modern technology cannot fully cater to the detection and monitoring of corn diseases. Besides traditional detection methods, new technologies such as Artificial Intelligence, Image Processing, Artificial Neural Networks, and Deep Learning are being utilized for disease detection. These methods and techniques enable effective and swift diagnosis of diseases, allowing for technological interventions when necessary. In this study, images of four different corn diseases and healthy corn were gathered and analyzed using the K-Nearest Neighbors Algorithm, Random Forest Algorithm, and Artificial Neural Networks. These algorithms trained and produced learned models in artificial intelligence. Following the training process, a model was created and compared with images of healthy corn, corn rust, leaf spots, and leaf blights. The success rates in detecting corn leaf diseases are as follows: K-Nearest Neighbors Algorithm at 97%, Random Forest Algorithm at 97.6%, and Artificial Neural Networks at 97.7%. Based on these results, it is anticipated that the created Artificial Neural Network model, with its high accuracy rate, could be used for identifying corn diseases and could serve as a guide for future research endeavors.

DOI: 10.59940/jismar.1384930

1. GİRİŞ (INTRODUCTION)

Tarım ve tarımsal sektörün ilerlemesi, küresel anlamda yoksulluğun azaltılmasına dair en etkili hususlardan biridir. Küresel kalkınma hedeflerine ulaşma yolunda sağlam, sürdürülebilir ve kapsayıcı gıda sistemleri kritik bir öneme sahiptir. Ortak refahı artırmak ve 2050 yılına kadar tahmini 9,7 milyar insanı beslemek adına tarımsal kalkınma, en etkin stratejilerden biri olarak öne çıkmaktadır.

Tarım, ekonomik büyüme için çok önemlidir, çünkü dünyanın GSYİH(Gayri Safi Yurt İçi Hasıla)'sinin %4'üne ve bazı az gelişmiş ülkelerde bu oran GSYİH 'nın %25'ine kadar çıkabilmektedir [1].

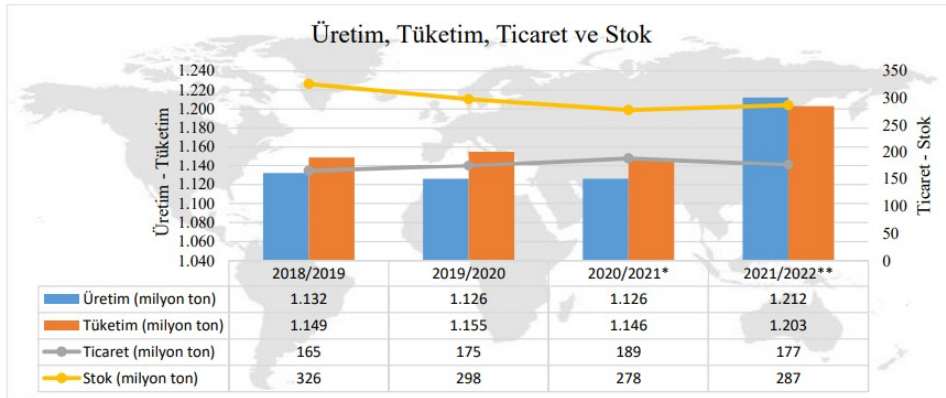
Tarımsal alanda, özellikle sebze üretiminde, hastalıkların erken teşhisi ve sınıflandırılması, üreticilerin hastalıkları önlemek için alacakları tedbirlerin yanı sıra ekonomik kayıpların ve üretim kayıplarının azaltılmasına sebep olmaktadır. Uzmanlar uzun süredir sebze ve meyve hastalıklarını çiplak gözle izleyerek tespit etmektedirler. Ancak, bu yöntemler hem zaman alıcıdır hem de bazı hastalıklar için yetersiz veya yanıltıcı olabilmektedir. Sebze ve meyvelerdeki hastalıklar, belirli görünür belirtiler

biraktığından, yapay zeka teknikleri sebzeledeki bu kusurların görüntü analizini yapma imkanı sunmaktadır.

Mısır, tek yıllık bir tahıl bitkisi olup özellikle sıcak iklimlerde yetişen Buğdaygiller ailesine ait bir bitkidir [2]. Mısır, tarımının binlerce yıldır yapıldığı ve uzun bir tarihe sahip nadir bitkilerden biridir. İklim çeşitliliği göz önüne alındığında, mısır dünya genelinde ılıman, subtropikal ve tropikal iklim kuşaklarında yetiştirilebilme özelliğine sahiptir.

Dünya genelinde, buğday ve pirinçten sonra en fazla tarımı yapılan tahıl bitkisi olarak mısır öne çıkmaktadır. Yüzde seksen oranında gelişmekte olan ülkelerde bulunan yaklaşık 70 milyon çiftçi ailesinin genellikle mısır tarımıyla meşgul olduğu bilinmektedir.

Uluslararası Hububat Konseyi'nin verilerine göre, 2021/2022 pazarlama döneminde küresel mısır üretiminin 1,21 milyar ton, tüketimin ise 1,20 milyar ton olması öngörülmektedir. Küresel mısır ticaretinin ise 177 milyon ton, stok miktarının ise 287 milyon ton olacağı tahmin edilmektedir. [3].



Kaynak: IGC, *Tahmin, **Öngörü, Erişim Tarihi: 03.01.2022

Şekil 1. Dünya Mısır Üretim, Tüketim Ve Stok Miktarları (World Corn Production, Consumption and Inventory Quantities)

Şekil 1'e göre dünya mısır üretim, tüketim ve stok miktarı verilmiş olup, Dünya genelinde, ekiliş alanı bakımından buğday ve çeltikten sonra üçüncü sırada yer alan mısır, üretim miktarı açısından önde gelen bir konumda bulunmaktadır. ABD, Çin, Brezilya, Arjantin, Meksika, Hindistan, Ukrayna ve Endonezya gibi ülkeler en yüksek mısır üretimine sahipken Türkiye, üretim sıralamasında 23. sırada yer almaktadır. Son on yılda, dünya çapında mısır ekim alanları %24 oranında genişlerken üretimde %42,3 oranında bir artış yaşanmıştır. Bu durum, mısır tarımında tekrar edilen ekimler ve pestisit kullanımı gibi unsurların ürün verimliliği ve kalitesini olumsuz etkilemesiyle ilişkilendirilirken,

bu etkenler zamanla daha belirgin hale gelmektedir [2].

Mısır bitkisi, gelişme süreci boyunca patojenlerin saldırısına maruz kalmasıyla çeşitli hastalıklara yol açabilir (Genç Kesimci, T. 2022). Ancak, mısır bu patojenlere oldukça hassas bir tepki göstermektedir. Hastalıklar genellikle mısır bitkisinin büyümesini bozarak üretim miktarında azalmaya yol açarlar [4]. Hastalığın etki derecesi, mısırın hastalık seviyesine bağlıdır. Hastalığın etkilediği bitkilerin genellikle büyümesi bozulur ve bitki dokuları ile hücrelerinin normal aktivitesi bozulur. Hastalıktan etkilenen mısır bitkileri kuruyabilir, boy atmada kısıtlanabilir, renk değişiklikleri gösterebilir ve yapraklar sararır

solabilir veya kuruyabilir [5].

Fungal hastalıklar, temel etkenler arasında yer alır. Mısırdaki yaprak yanıklığı gibi fungal hastalıklar, başlıca ürün kayıplarına neden olan hastalıklardan biridir. Bu hastalıklar, dünya genelinde neredeyse her mısır yetiştirilen bölgede görülen ve uygun iklim koşullarında %20 ile %70 arasında değişen verim kayıplarına sebep olabilen fungal kökenli rahatsızlıklardır.

Ülkemizde de mısır tarımının yapıldığı bölgelerde, uygun iklim koşulları sıklıkla hastalığın ortaya çıkmasına yol açar; bu durum, dünya genelinde benzer bir eğilimi yansıtmaktadır. Mısır hastalıklarının teşhis edilmesi için bitki hastalıklarının otomatik tespiti için çeşitli uzman sistemler geliştirilmiştir [6]. İnternetin hızlı, kolay ve ücretsiz erişimi sayesinde birçok yapay zekâ uygulaması geliştirilebilmektedir. Yapay zekâ terimi, makine öğrenimi ve derin öğrenme gibi konuları içerir (LeCun ve ekibi, 2015). Derin öğrenmedeki ilerlemeler, yapay zekânın görüntü işlemede kullanımına olan ilgiyi artıran ana etkindir [7]. Son yıllarda bilgisayarlı görü alanında yapılan çalışmalar, derin öğrenme ve makine öğrenmesi tekniklerinin kullanılarak başarılı yapay zekâ modellerinin oluşturulduğunu göstermektedir. Örneğin, insanlığın yaşamını sürdürebilmesi ve sağlıklı beslenebilmesi için gereken tarım ürünlerinin yetiştirilmesinde bu uygulamalar önemli bir rol oynamaktadır. Mısır üretiminde verimliliği azaltan ve yapraklarda görülen hastalıkların tespiti de bu yöntemlerle başarıyla gerçekleştirilmektedir. Bu alanda yapılmış birçok araştırma literatürde bulunmaktadır [8].

1.1. Literatür Taraması (Literature Review)

Literatürdeki bir çalışmada, mısırın hastalıklarını tespit etmek için farklı görüntü işleme tekniklerini kullanarak bir sistem geliştirmeyi amaçlamışlar. RGB (Red Green Blue) renklerin tanınmasını sağlamak için çeşitli özellik çıkartma yöntemleri kullanmışlardır. Destek vektör makineleri, karar ağaçları, rastgele orman ve naive bayes algoritmaları gibi çeşitli algoritmaları denemişler ve çoğu algoritma başarılı sonuçlar vermiştir [4]. Başka bir çalışmada, mısır hastalıklarının sınıflandırılmasında destek vektör makineleri (SVM) yerine genetik algoritma destek vektör makineleri (GA-SVM) adlı bir algoritmanın kullanılarak SVG algoritmasında başarılı sonuçlar elde edilebileceği gözlemlenmiştir [9]. Panigrahi vd., parametrelerin ayarlanmasıyla geliştirilmiş bir CNN modeli kullanarak %98.78'lik bir ortalama doğruluk oranına erişmişlerdir. Bu geliştirme, düzeltilmiş doğrusal birim aktivasyon fonksiyonu ile bir Adam optimize edicisi kullanılarak gerçekleştirilmiştir. [10].

Mısır hastalıklarının sınıflandırılması amacıyla

yapılan başka bir çalışmada Evrişimli sinir ağları (CNN) algoritmasının eğitimi için bir akıllı telefon kamerası kullanılarak mısır yaprağı hastalıklarının görüntüleri toplanmış ve bu görüntüleri tanıyan ve sınıflandıran bir CNN algoritması ile %92.85 başarı elde edildiği görülmüştür [11].

Mısır hastalıklarını sınıflandırmak için LeNet temelli bir CNN kullanılarak geliştirilen sınıflandırma algoritmasının başarı oranının %97.89 olduğu tespit edilmiştir [12].

Çiftçilerin meyve hastalıklarını tespit etmelerine yardımcı olmak amacıyla bir sistem üzerinden meyve fotoğraflarını yükleyerek bir teknik önerildi. Bu yöntemde, önceden öğrenilmiş bir veri kümesi olan nar tohumlarından elde edilen veriler kullanıldı. Kullanıcılar, çeşitli fotoğrafları sisteme yükleyerek analiz için katkıda bulundular. Bu fotoğraflar daha sonra eğitim veri setindeki görüntülerle karşılaştırılarak hastalık şiddeti belirlendi. Önerilen yöntemin deneysel sonuçlarına göre %82 doğruluk elde edildi [13].

Kapon, mısır yaprağı hastalıkları üzerine yaptığı çalışmada EfficientNet adlı CNN mimarisini tercih etmiştir. Yapılan yöntemde, dört farklı sınıf için sırasıyla %91,30, %97,71, %93,10 ve %100 doğruluk oranları elde edilmiştir [14].

Whxna, çalışmalarında SqueezeNet adlı bir CNN mimarisini tercih etmiş ve optimize edici olarak Adam yöntemini kullanmıştır [15].

Bilgisayarlı görü kullanılarak, mısır hastalıklarının 5 farklı kategorisine yönelik sınıflandırma işlemi %80'in üzerinde bir başarı elde etmiştir [16].

AlexNet'in kullanıldığı bir çalışmada, oluşturulan sınıflandırıcının %98.62'lik bir başarı oranına sahip olduğu gözlemlenmiştir [17].

Mısır kuraklığını belirleme ve kategorize etme amacıyla gerçekleştirilen bir çalışmada, derin konvolüsyonel sinir ağının kullanıldığı tespit edilmiştir. Elde edilen sonuçlar, bu önerilen sistemin tanımlama ve sınıflandırma doğruluğunun sırasıyla %98.14 ve %95.95 olduğunu göstermektedir [18].

Song ve ekibi, yaprak hastalıklarının tespiti ve sınıflandırılmasında sayısal görüntü işleme teknikleri, destek vektör makineleri, yapay sinir ağları ve diğer metodları kullanmışlardır. Farklı mısır yaprağı hastalıklarını %89.6 oranında doğrulukla tespit etmek için bir SVM yaklaşımı benimsemişlerdir. Bu SVM tabanlı sınıflandırma metodolojisi, en yüksek doğruluğu sunmasa da hem küçük veri setleri hem de büyük veri setleri için kullanışlıdır [19].

Rage, mısır yaprağı hastalıkları üzerine yaptığı çalışmada VGG16 adlı bir CNN mimarisini tercih etmiş ve optimize edici olarak Adam yöntemini kullanmıştır. Çalışmada mısır yaprakları için elde edilen doğruluk oranı %90,82 olarak kaydedilmiştir [20].


1.2. Veri Seti Özellikleri (Data Set Characteristics)

Bu çalışmada kullanılan veri seti kaggle.com platformundan alınmıştır (<https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset>).

Orange Data Mining uygulaması, veri analizi için veri birimine odaklanan bir platformdan yararlanılmıştır. Bu yazılımın temel amacı, veri analizi, veri madenciliği tekniklerinin kullanımı ve yeni modellerin oluşturulmasıyla bu modellerin değerlendirilmesidir.

Orange Data Mining platformu, açık kaynaklı bir araç setidir ve kullanıcılara veri hazırlama, veri analizi ve model oluşturma gibi olanaklar sunar. Veri madenciliği işlemleri, görsel programlama veya Python betikleme yöntemleriyle Orange Data Mining'de gerçekleştirilebilir.

Bu çalışmada, 4 ayrı veri grubu üzerinde çalışılmıştır. Bu gruplardan üçü hastalıklı verilerden oluşurken bir grup sağlıklı verilerden oluşmaktadır. Veri setindeki materyaller JPG formatındadır ve toplamda 1306 adet Mısır Pası, 574 adet Yaprak Lekesi, 1146 adet Yaprak Yanığı ve 1162 adet Sağlıklı mısır yaprağı olmak üzere 4188 resim bulunmaktadır.



Şekil 2. Veri Setinden Örnek Resimler (Sample Images from the Data Set)

Şekil 2'de sunulan veri setinden örnek resimler gösterilmiştir. Bu resimler, (1) numarada mısır pası örneği, (2) numarada sağlıklı veri örneği, (3) numarada yaprak lekeli örneği ve (4) numarada yaprak yanığı veri örneği olarak tanımlanmaktadır. Veri setinin dağılımı ise Tablo 1'de sunulmuştur.

Tablo 1. Çalışmada kullanılan veri sayıları ve yüzdeleri (The Numbers and Percentages of the Data Used in the Study)

Kullanım Alanı	Veri Sayısı	Yüzde(%)
Eğitim(training)	3351	%80
Test(testing)	837	%20
Toplam	4188	%100

Araştırmanın temel amacı, günümüzde sıkça karşılaşılan mısır yaprağı hastalıklarını hızlı ve kesin bir biçimde öngörebilen bir yapay zekâ modelinin oluşturulmasıdır. Bu çalışmanın hedefleri arasında

tarım sektöründe yapay zekânın benimsenmesini desteklemek ve bu yolla hastalık teşhisinde zaman ve çaba kaybını en aza indirgeyerek doğru teşhisi yapmak yer almaktadır. Ek olarak, bu çalışmanın bir diğer amacı, geliştirilen yapay zekâ modelinin çeşitli ve geniş veri setlerini analiz ederek kendini sürekli olarak eğitmesi ve teşhis doğruluğunu artırmasıdır. Bu sayede, üretim maliyetlerinde ve zaman kullanımında tasarruf sağlanması öngörülmektedir.

2. YÖNTEM (METHOD)

Bu bölümde, çalışma sürecinde önerilen model ve adımlar ayrıntılı bir şekilde sunulmuştur. İlk aşamada, kullanılan algoritmaların açıklaması yapılmış, daha sonra veri setinin edinilme ve hazırlanma süreci açıklanmış ve en nihayetinde modelin oluşturulma süreci detaylandırılmıştır. Model oluşturulurken tercih edilen araç, Orange veri analiz programıdır.

Bu çalışmada, mısır yapraklarındaki hastalıkların tespiti için görüntü işleme ve sınıflandırma araçlarını kullanan, yapay zekâ temelli bir yöntem ile Orange veri analiz platformu incelenmiştir. Bu sistem için, hastalıklı ve sağlıklı mısır yaprağı resimleri JPG formatında girdi olarak sunulmuş ve bu resimler üzerinde hastalık varlığıyla ilgili bir analiz görüntü işleme teknikleriyle gerçekleştirilmiştir.

2.1. Algoritma Seçimi (Algorithm Selection)

Orange veri analiz programı, modellerin oluşturulmasında tercih edilen bir araçtır. Bu araştırma, mısır yapraklarında hastalıkların teşhisini amaçlamaktadır. Bu hedef doğrultusunda, Rastgele Orman Algoritması, K-En Yakın Komşu algoritması ve Yapay Sinir Ağları gibi çeşitli algoritmalar kullanılmıştır. Çalışmada, üçten fazla makine öğrenmesi algoritmasıyla testler gerçekleştirilmiş ve en yüksek başarı oranını sunan KNN, Naïve Bayes ve Yapay Sinir Ağları tercih edilmiştir.


2.1.1. K-En Yakın Komşu (KNN) Algoritması

(K-Nearest Neighbor (KNN) Algorithm)

Yeni verinin örnek veri setine katılması durumunda, mevcut verilere olan benzerliği hesaplanır ve k en yakın komşusuna bakılır. K-En Yakın Komşu (KNN) algoritması, yeni veriyi var olan verilerle karşılaştırarak uzaklığını hesaplayıp sınıflandıran bir yapıya sahiptir. KNN, temel bir makine öğrenimi algoritmasıdır. Yeni bir veri örneği eklendiğinde, bu örneğe en yakın olan k veri belirlenir ve yeni örneğin sınıfı bu k verinin sınıfına dayalı olarak belirlenir. [21].

K-En Yakın Komşu (KNN) algoritması, yeni veriyi alır ve ardından uzaklıkların hesaplanmasını gerçekleştirir.

Bu hesaplama sonrasında en yakın komşular belirlenir ve bu modele göre veri, mısır pası, yaprak lekesi, yaprak yanığı veya sağlıklı olup olmadığına göre sınıflandırılır. Şekil 3'te çıktı katmanlarına göre KNN modeli verilmiştir.



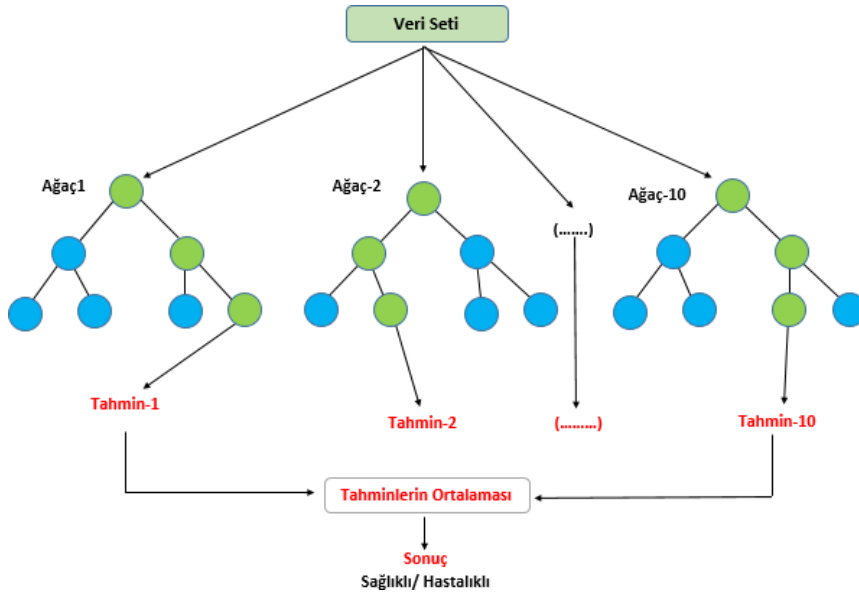
Şekil 3. KNN modeli (KNN model)

2.1.2. Rastgele Orman Algoritması

(Random Forest Algorithm)

Rastgele Orman, Leo Breiman ve Adele Cutler tarafından geliştirilmiş bir sınıflandırma yöntemidir. Bu yöntem, oylama tekniğini içerir ve birden fazla karar ağacının bir araya getirilmesiyle oluşturulur. Her bir ağaç, kendi sınıfını oylar ve kazanan sınıf bu oylarla belirlenir. Karar ağaçlarının oluşturulmasında, bağımsız bir şekilde veri setinden bootstrap tekniğiyle seçilen örnekler kullanılır. [22].

Çalışmada Rastgele Orman algoritması modeli Şekil 4'te kullanılmıştır. Bu modelde 10 ağaç yer almaktadır ve elde edilen sonuçlar için tahminlerin ortalaması alınmıştır.



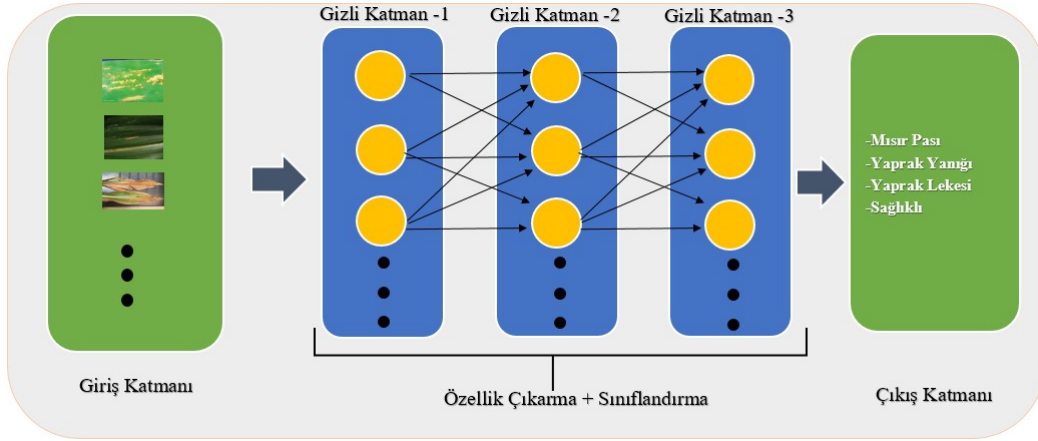
Şekil 4. Rastgele orman modeli (Random forest model)

2.1.3. Yapay Sinir Ağı Algoritması

(Artificial Neural Network Algorithm)

Yapay sinir ağları, insan beynindeki nöronlar gibi bağlantılı elemanlardan oluşur. Bu elemanlar bellek kapasitesine sahiptir ve bilgi işleme yeteneklerine sahiptir. Yapay Sinir Ağları, biyolojik sinir


sisteminin yapı ve yeteneklerini taklit etmektedir. Ayrıca, kendi kendine öğrenme, bilgi depolama, yorumlama gibi yetenekleri olan bir algoritma yapısıdır [23]. Çalışmada kullanılan YSA modelinde 5 gizli katman ve 15 düğüm bulunmaktadır. Bu YSA algoritma modeli Şekil 5'te verilmiştir.



Şekil 5. Yapay sinir ağı modeli (Neural Network model)

3. BULGULAR (FINDINGS)

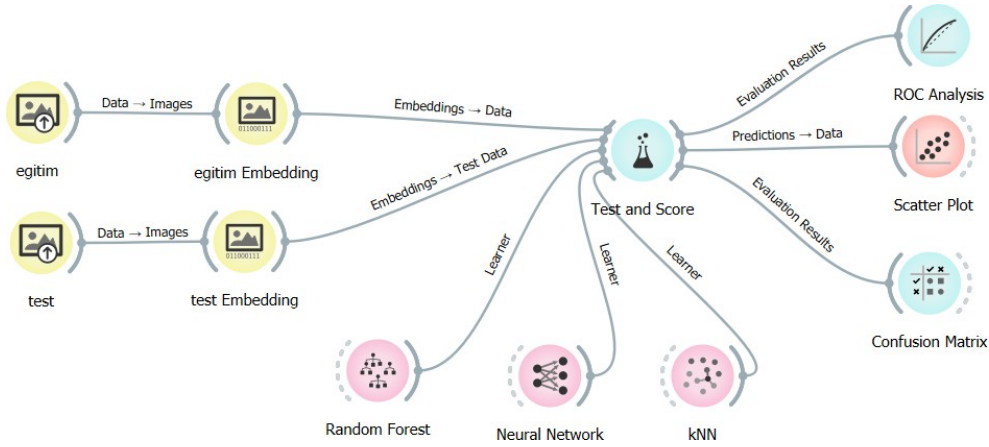
Modelin eğitimi için, mısır yaprağı hastalığına ait görüntüler ile sağlıklı mısır yaprağı görüntüleri kullanılmıştır. Bu nedenle modelin giriş değerleri belirlenmiştir. Bu giriş değerleri, mısır pası, yaprak lekesi, yaprak yanığı ve sağlıklı mısır yaprağı görüntülerine aittir. Şekil 6'da çalışmada kullanılan veri görüntülerinden örnekler verilmiştir.



Şekil 6. Veri setinden örnek veri görüntüleri (Sample data images from the data set)

Çalışmanın Orange veri analizi ekranı, Şekil 7'de sunulmuştur. Orange veri analizi programında, veri görüntüleri eğitim ve test verisi olarak iki farklı gruba ayrılır. Bu veriler Embedding bölümünde işlenir ve daha sonra belirlenen üç farklı algoritma kullanılarak modeller oluşturulur. Elde edilen bu modellerin sonuçları ve başarı değerleri Test and


Score bölümünde tablo formatında sunulur. Test ve Skor bölümünden sonra, test verileri algoritmalarla ilişkilendirilerek görselleştirme yapılmıştır. Bu görseller, her bir algoritmanın yüzdelik doğruluk değerlerini, çıkış katmanına göre doğruluk ve kayıp grafiklerini içermektedir.



Şekil 7. Çalışmanın orange veri analiz ekranı (Orange data analysis screen of the study)

Yapay sinir ağının işlediği veriler, giriş, gizli ve çıkış katmanlarından geçerek mısır yaprağı görüntülerinin hastalıklı olup olmadığını sınıflandırmak için kullanılmaktadır. Şekil 8'de, çalışmada kullanılan algoritmalar için Karışıklık Matrisi (Confusion Matrix) değerleri sunulmuştur. Bu algoritmaların

performansı değerlendirildiğinde, 834 test verisi içinde KNN'in 728, Yapay Sinir Ağı'nın 743 ve Rastgele Orman'ın 717 doğru tahminde bulunduğu gözlemlenmiştir. En yüksek başarıyı Yapay Sinir Ağı algoritması göstermiştir.



Şekil 8. Algoritma modelleri karışıklık matrisi sonuçları (Algorithm models results of the confusion matrix)

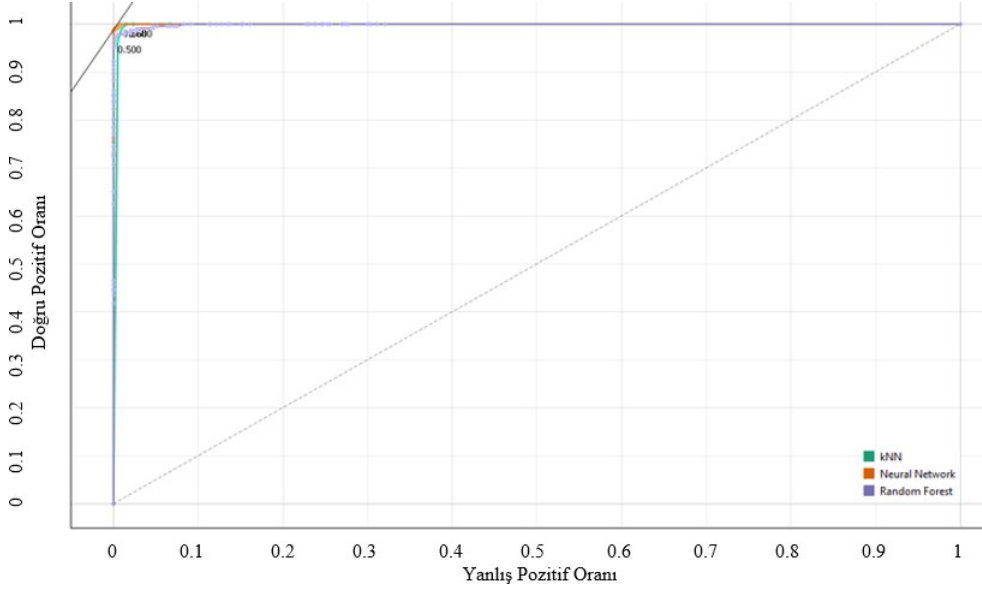
Tablo 2'de projede kullanılan algoritmaların eğitim ve test verilerine göre yüzdelik değerler sunulmuştur. Yapay Sinir Ağı, %97.0 eğitim ve %89.1 test doğruluğuyla en üstün sonucu göstermiştir.

Tablo 2. Modellerin karşılaştırılması (Comparison of models)

Model Adı	AUC	Sınıflandırma Doğruluğu	F1 Skoru	Kesinlik	Duyarlılık
Yapay Sinir Ağı	0.970	0.891	0.891	0.891	0.891
Rastgele Orman	0.967	0.877	0.859	0.867	0.860
kNN	0.961	0.873	0.872	0.875	0.873


Roc grafiği, herhangi bir sınıflandırma modelinin performansını değerlendirmek için kullanılan temel metriklerden biridir. Özellikle dengesiz veri setleriyle çalışıldığında, makine öğrenimi algoritmalarının performansını değerlendirmek için en sık tercih edilen ölçümlerden biridir. Çalışmada sağlıklı mısır, mısır pası, yaprak lekesi ve yaprak yanığı için Roc doğruluk grafikleri şekil 9, şekil 10, şekil 11 ve şekil 12'de sunulmuştur. Grafiklerde,

kullanılan algoritmaların doğruluk oranları, doğru pozitif (TP) ve yanlış pozitif (FP) değerlerine göre belirlenmiştir. Şekil 9'da sağlıklı mısır verileri için kNN 0.989, yapay sinir ağı 0.994 ve rastgele orman algoritması için 0.987 doğruluk oranları gözlemlenmiştir. Grafik incelendiğinde, yapay sinir ağı algoritmasının diğerlerine göre daha başarılı bir doğruluk oranı sergilediği belirlenmektedir.




Şekil 9. Sağlıklı mısır verileri için roc analiz grafiği (Roc analysis graph for healthy corn data)

Şekil 10'da mısır pası hastalığı verileri için kNN 0.947, yapay sinir ağı 0.950 ve rastgele orman algoritması için 0.940 doğruluk oranları sonucu ortaya çıkmıştır. Grafiğe göre yapay sinir ağı algoritmasının doğruluk oranının diğerlerine göre başarılı olduğu sonucuna varılmıştır.




Şekil 10. Mısır pası hastalığı verileri için roc analiz grafiği (Roc analysis graph for maize rust disease data)

Şekil 11'de yaprak lekeli hastalığı verileri için kNN 0.922, yapay sinir ağı 0.924 ve rastgele orman algoritması için 0.911 doğruluk oranları sonucu ortaya çıkmıştır. Yapay sinir ağı algoritmasının doğruluk oranının diğerlerine göre daha başarılı olduğu görülmektedir.



Şekil 11. Yaprak lekesi hastalığı verileri için roc analiz grafiği (Roc analysis graph for leaf spot disease data)

Şekil 12’de yaprak yanığı hastalığı verileri için kNN 0.890, yapay sinir ağı 0.912 ve rastgele orman algoritması için 0.869 doğruluk oranları ortaya çıkararak, yapay sinir ağı algoritmasının doğruluk oranının diğerlerine göre daha başarılı olduğu sonucuna varılmıştır.



Şekil 12. Yaprak yanığı hastalığı verileri için roc analiz grafiği (Roc analysis graph for leaf burn disease data)

4. SONUÇ, TARTIŞMA VE ÖNERİLER

(CONCLUSION, DISCUSSION AND SUGGESTIONS)

Elde edilen sonuçlar, oluşturulan yapay sinir ağı modelinin mısır yaprağı hastalığını tahmin etme yeteneğinin eğitimde %97 ve test aşamasında %89 başarı oranıyla olduğunu göstermektedir. Yapılan araştırmada kullanılan yapay zekâ tekniklerinin, geleneksel yöntemlere göre mısır yaprağı hastalıklarını tespit etme konusunda daha etkili olduğu belirtilmektedir. Bu önerilen sistem, mısır hastalıklarının tespitinde zaman ve maliyet açısından büyük bir tasarruf sağlamaktadır. Yapılan çalışma,

yapay sinir ağı modelinin sınıflandırma ve kalıp tanıma uygulamalarında oldukça etkili olduğu sonucuna varmaktadır. Bu sistem, hastalığın otomatik olarak teşhis edilmesine katkıda bulunmayı hedeflemektedir. Oluşturulan model, değerlendirme aşamasında sadece www.kaggle.com sitesinden alınan yaprak resimleriyle değerlendirme yapmaktadır. Farklı bölgelerden ve daha geniş bir veri setinden elde edilecek bilgiler, daha kapsamlı bir değerlendirme yapabilen bir modele ulaşarak daha doğru sonuçlara ulaşmayı sağlayabilir. Bu verilerin kullanımı, küresel, ulusal veya bölgesel düzeyde çeşitli analizlerin ve yeni bilimsel

araştırmaların yapılmasına büyük katkı sağlayabilir. Belki de bu tür araştırmalar, tarımsal alanlarda geniş bir gelişim sağlamak adına gerçekleştirilecektir. Sonuçlar, düşük hata oranı ve minimum maliyetle hastalık tespitinin yapay zekânın tarım ve bitki yetiştiriciliği alanında kullanılması gerekliliğini vurgulamaktadır. Mobil uygulama geliştirilerek çiftçilerin kullanımına sunulabilir ve bu sayede çekilen resimlerle veri setleri zenginleştirilerek tahmin hassasiyeti artırılabilir. Yapay sinir ağı algoritması, diğer sınıflandırıcılar gibi, mısır yaprağı hastalıklarının teşhisinde önemli bir tanı yöntemi olarak değerlendirilebilir.

KAYNAKLAR (REFERENCES)

- [1] Dünya Bankası (30 Eyl 2022), “Genel Bakış”. Erişim Adresi: <https://www.worldbank.org/en/topic/agriculture/overview>
- [2] Turgay, E. B., Büyük, O., Tunalı, B., Kurt, Ş., Akçalı, E., Baran, B., & Kansu, B. (2017). Türkiye’de önemli mısır (*Zea mays L.*) alanlarında Kuzey [Exserohilum turcicum (Pass.) KJ Leonard & Suggs] ve Güney [Bipolaris maydis (Y. Nisk. & C. Miyake) Shoemaker] mısır yaprak yanıklığı hastalıklarının yaygınlığı. Griffiths, M., (1999), “Internet addiction: Fact or fiction?” *The Psychologist*, c. 12, S. 5, s. 246–251.
- [3] Tarım ve Orman Bakanlığı (Ocak 2022, Sayı 19). Dünyada Mısır [Mısır bülteni]. Erişim adresi: <https://www.tarimorman.gov.tr/BUGEM/Belgeler/B%C3%BCltenler/OCAK%202022/M%C4%B1s%C4%B1r%20Ocak%20B%C3%BClteni.pdf>Karaman
- [4] 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.
- [5] Khoirunnisak, K. M. (2020). Sistem Pakar Diagnosa Penyakit pada Tanaman Jagung dengan Metode Dempster Shafer. Publikasi Tugas Akhir S-1 PSTI FT-UNRAM.
- [6] Wiesner-Hanks, T., Stewart, E. L., Kaczmar, N., DeChant, C., Wu, H., Nelson, R. J., ... & Gore, M. A. (2018). Image set for deep learning: field images of maize annotated with disease symptoms. *BMC research notes*, 11(1), 1-3.
- [7] Le, E. P. V., Wang, Y., Huang, Y., Hickman, S., & Gilbert, F. J. (2019). Artificial intelligence in breast imaging. *Clinical radiology*, 74(5), 357-366.
- [8] Göksu, M., Sünnetci, K. M., & Alkan, A. Derin öğrenme ağları kullanılarak mısır yapraklarında hastalık tespiti. *Computer Science, (Special)*(2021), 208-216.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] Ahila Priyadharshini, R., Arivazhagan, S., Arun, M., & Mirnalini, A. (2019). Maize leaf disease classification using deep convolutional neural networks. *Neural Computing and Applications*, 31(12), 8887-8895.
- [13] Bhangе, M., & Hingoliwala, H. A. (2015). Smart farming: Pomegranate disease detection using image processing. *Procedia computer science*, 58, 280-288.
- [14] Kapon, O. (2022, February). Kaggle: <https://www.kaggle.com/code/omreekapon/corn-and-maizediseases-classification/notebook>. Erişim: 04.10.2022
- [15] Whxna. (2022, August). Kaggle: <https://www.kaggle.com/code/jiaoowoguanren/corn-ormaize-leaf-dataset-tf-squeezenet/notebook>. Erişim: 04.10.2022
- [16] Zhao, Y.-X., Wang, K.-R., Bai, Z.-Y., Li, S.-K., Xie, R.-Z., & Gao, S.-J. (2009). Research of Maize Leaf Disease Identifying Models Based Image Recognition. *Crop Modeling and Decision Support*, 1(2004), 317–324. https://doi.org/10.1007/978-3-642-01132-0_35.
- [17] Lv, M., Zhou, G., He, M., Chen, A., Zhang, W., & Hu, Y. (2020). Maize Leaf Disease Identification Based on Feature Enhancement and DMS-Robust Alexnet. *IEEE Access*, 8, 57952–57966. <https://doi.org/10.1109/ACCESS.2020.2982443>.
- [18] An, J., Li, W., Li, M., Cui, S., & Yue, H. (2019). Identification and classification of maize drought stress using deep convolutional

- neural network. *Symmetry*, 11(2), 1–14. <https://doi.org/10.3390/sym11020256>.
- [19] 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.
- [20] Rage, S. (2022). Kaggle: <https://www.kaggle.com/code/sailikhitara/m-aize-mutantclassification-using-vgg16/notebook>. Erişim: 04.10.2022
- [21] Kiliç, d., Borandağ, E., Yücalar, f., Tunali, v., Şimşek, M., & Özçift, A. (2016). Knn Algoritması Ve R Dili Ile Metin Madenciliği Kullanılarak Bilimsel Makale Tasnifi. *Marmara Fen Bilimleri Dergisi*, 28(3), 89-94.
- [22] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- [23] Elmas, Ç. (2016). *Yapay Zeka Uygulamaları 3*. Baskı. Ankara: Seçkin Yayıncılık.