

Bitki hastalıklarını tespitinde derin öğrenme: ResNet modelinin etkinliği

Cihan TOPCU¹
Peri GÜNEŞ^{2*}

Geliş tarihi / Received: 20.12.2023

Düzeltilerek geliş tarihi / Received in revised form: 25.02.2024

Kabul tarihi / Accepted: 01.03.2024

DOI: 10.17932/IAU.ABMYOD.2006.005/abmyod_v19i69002

Özet

Bitki hastalıklarının erken tespiti, tarım sektörünün kalbinde yer almakta ve hem verimi artırmak hem de ekosistemdeki dengenin korunması açısından vazgeçilmez bir öneme sahiptir. Gelişen yapay zeka teknolojileri, bu alanda devrim niteliğinde ilerlemeler sağlayarak, hastalıkların hızlı ve etkin bir şekilde tanınmasına olanak tanımıştır. Bu çalışmada kullanılan ResNet modeli, derin öğrenme algoritmalarının en iyilerinden biri olarak öne çıkmakta, bitki yaprakları üzerindeki karmaşık özellikleri saptayarak, geniş bir hastalık spektrumunu doğru bir şekilde sınıflandırabilme kapasitesini sergilemektedir. ResNet 'in bu üstün performansı, tarımsal verimliliği artırma ve bitki sağlığını koruma konusunda kritik bir adım niteliğindedir.

Modelin eğitim süreci boyunca detaylı bir şekilde incelenen veriler, ResNet modelinin bitki hastalıklarını tespit etmede olağanüstü bir başarıya ulaştığını göstermiştir. Elde edilen %99'luk başarı oranı, yapay zekâ tabanlı görüntü işleme teknolojilerinin tarımsal uygulamalarda nasıl hayati bir rol oynayabileceğinin açık bir göstergesidir. Bu seviyede bir doğruluk, özellikle zorlu dış mekân koşullarında ve çeşitlilik gösteren yaprak örnekleri üzerinde gerçekleştirilen analizler için özellikle etkileyicidir ve modelin geniş bir hastalık spektrumunu anlayabilme ve sınıflandırabilme yeteneğini kanıtlar niteliktedir. Bu sonuçlar, ResNet modelinin bitki hastalıkları teşhisinde bir endüstri standardı olarak benimsenebileceğini ve tarımsal uygulamalarda dönüşüm yaratabileceğini işaret etmektedir.

¹ İstanbul Aydın Üniversitesi, cihantopcu@stu.aydin.edu.tr. Orcid: 0009-0003-3702-9675

^{2*} Nişantaşı Üniversitesi, peri.gunes@nisantasi.edu.tr. Orcid:0009-0002-9080-3239

Bu çalışmanın sonuçları, yapay zekâ destekli bitki hastalığı tespit sistemlerinin tarım sektörü için sunduğu katkılarının ve potansiyelin altını çizmektedir. Gelişmiş ResNet modelinin uygulanmasıyla, hastalıkların erken ve doğru bir şekilde tanınması mümkün kılınarak tarımsal süreçlerin verimliliği ve sürdürülebilirliği önemli ölçüde iyileştirilmektedir. Bu teknolojik ilerleme, hastalıkların hızlı tedavisini ve önlenmesini sağlayarak, genel olarak tarım üretiminde kalite ve güvenliğin artırılmasına olanak tanımaktadır. Bu başarı, ResNet 'in derin öğrenme yaklaşımının, gerçek dünya tarımsal sorunlarına uygulanabilir ve etkili çözümler sunma gücünü kanıtlamaktadır.

Anahtar Kelimeler: *Bitki hastalıkları, Erken tespit, Yapay zekâ, ResNet, Derin öğrenme, Görüntü işleme, Doğruluk oranı, Veri analizi, Hastalık teşhisi,*

Deep learning in plant disease detection: effectiveness of resnet model

Abstract

Early detection of plant diseases holds a central place in the agriculture sector and is indispensable for both increasing yield and maintaining ecosystem balance. The advancements in artificial intelligence technologies have revolutionized this field, enabling rapid and effective identification of diseases. The ResNet model used in this study stands out as one of the best deep learning algorithms, demonstrating the ability to accurately classify a wide spectrum of diseases by detecting complex features on plant leaves. This superior performance of ResNet is a critical step in enhancing agricultural productivity and protecting plant health.

The data examined in detail during the training process of the model show that the ResNet model has achieved extraordinary success in detecting plant diseases. The achieved 99% success rate is a clear indicator of how AI-based image processing technologies can play a vital role in agricultural applications. Such accuracy, especially in challenging outdoor conditions and on diverse leaf samples, is particularly impressive and proves the model's ability to understand and classify a wide disease spectrum. These results suggest that the ResNet model could be adopted as an industry standard in diagnosing plant diseases and create a transformation in agricultural applications.

The findings of this study underline the contributions and potential of AI-supported plant disease detection systems for the agriculture sector. With the implementation of the advanced ResNet model, early and accurate disease detection is made possible, significantly improving the efficiency and sustainability of agricultural processes. This technological progress allows for the rapid treatment and prevention of diseases, thereby enhancing the overall quality and safety in agricultural production. This success demonstrates the power of ResNet's deep learning approach to offer applicable and effective solutions to real-world agricultural problems.

Keywords: *Plant diseases, Early detection, Artificial intelligence, ResNet, Deep learning, Image processing, Accuracy rate, Data analysis, Disease diagnosis, Convolutional Neural Network (CNN)*

Giriş

Tarımsal üretimin, küresel gıda güvenliği açısından taşıdığı kritik önem, bitki hastalıklarının hızlı ve etkin bir şekilde teşhis edilmesini zorunlu kılmaktadır. Bu makale, tarım sektörünün bu sürekli önceliğine yanıt olarak, gelişmiş yapay zekâ tekniklerinin ve özellikle derin öğrenme algoritmalarının, tarımsal bitki hastalıkları teşhisinde nasıl kullanılabileceğini derinlemesine incelemektedir. Çalışmamız, bitki yaprağı görüntülerinden elde edilen veriler üzerinden çeşitli bitki türlerine ait hastalık belirtilerinin sınıflandırılması sürecine odaklanmaktadır. Bu süreç, bitki sağlığı yönetimi ve hastalık önleme stratejilerinin geliştirilmesinde yapay zekanın potansiyelini keşfetmek amacıyla tasarlanmıştır.

Küresel nüfusun sürekli artması ve iklim değişikliğinin tarımsal üretim üzerindeki etkileri göz önüne alındığında, tarım sektörünün karşılaştığı zorluklar da artmaktadır. Bu bağlamda, bitki hastalıklarının teşhis ve yönetimi, tarımsal verimliliği artırma ve gıda güvenliğini sağlama yolunda kritik bir rol oynamaktadır. Yapay zekâ ve derin öğrenme algoritmalarının kullanımı, bu zorluklara yenilikçi ve etkili çözümler sunma potansiyeline sahiptir. Makalemiz, bu teknolojilerin tarım sektörüne entegrasyonunu ve hastalık teşhisindeki etkinliklerini ele alarak, gelecekteki uygulamalar için bir yol haritası sunmayı hedeflemektedir.

Tarımsal üretimin küresel gıda güvenliği için oynadığı hayati rol, bitki hastalıklarının hızlı ve doğru bir şekilde teşhis edilmesinin önemini artırmaktadır. Gıda ve Tarım Örgütü (FAO) tarafından yapılan tahminlere

göre, küresel gıda üretiminin yaklaşık %20 ila %40'ı zararlılar ve hastalıklar tarafından etkilenmekte, bu da gıda güvenliği için ciddi bir tehdit oluşturmaktadır. Bu makale, gelişmiş yapay zeka tekniklerinin ve özellikle derin öğrenme algoritmalarının tarımsal bitki hastalıkları teşhisinde nasıl kullanılabileceğini ele alırken, aynı zamanda bu teknolojilerin tarım sektöründe nasıl uygulanabileceğini ve sürdürülebilir tarım uygulamalarına nasıl katkı sağlayabileceğini de tartışmayı amaçlamaktadır (Ganatra ve ark., 2020).

Son teknolojik gelişmeler, özellikle düşük maliyetli cihazların görüntü edinimi için yaygınlaşması, görüntü tabanlı teşhis uygulamaları için geniş ölçekte veri toplanmasını mümkün kılmıştır (Wang, 2021). Bilgisayar sistemlerinin, özellikle grafik işlemcilerinin (GPU'ların) hızlı gelişimi, derin öğrenme modellerinin doğal dil işleme, makine çevirisi, tıbbi görüntü analizi gibi birçok alanda dikkate değer başarılar elde etmesine olanak tanımıştır. Bu bağlamda, Internet of Things (IoT) ve sensör ağlarındaki ilerlemeler göz önüne alınarak, derin öğrenme algoritması temelli yeni bir bitki yaprağı tanımlama modeli tasarlanmıştır (Guo, 2020).

Bitki hastalıkları, doğrudan kötü etkiler yaratarak verim üzerinde olumsuz bir etkiye neden olmaktadır ve dünya genelinde yılda 20 milyar dolara kadar ekonomik kayıp tahmin edilmektedir. Coğrafi farklılıklar ve doğru tanılamayı engelleyebilecek çeşitli koşullar, araştırmacılar için önemli zorluklardan biridir. Geleneksel yöntemler, genellikle uzman görüşlerine, deneyime ve kılavuzlara dayanmaktadır; ancak bu yöntemler maliyetli, zaman alıcı ve doğruluk açısından sınırlamalara sahip olabilir. Bu makale, bitki hastalıklarının teşhisinde yapay zeka ve derin öğrenme algoritmalarının potansiyelini keşfetmeyi ve bu teknolojilerin tarım sektöründe nasıl uygulanabileceğini ele almaktadır (Guo, 2020).

Yapay zekâ, bilgisayar görüşü ve makine öğrenimi kullanımı, bitki hastalık tespit sürecini önemli ölçüde geliştirebilir ve bu alanlarda yapılan birçok araştırmada zaten uygulanmaktadır. Bu teknolojiler, bir hastalığın varlığını tespit etmenin ötesine geçerek, hastalığın şiddetini belirleme ve verilen bir bitki örneğindeki hastalık türünü doğru bir şekilde sınıflandırma yeteneğine sahiptir. İleri teknolojik yaklaşımlar, bitkilerde hastalık tespitinde de kullanılabilir. Bu nedenle, makine öğrenimi ve derin öğrenme yaklaşımları, özellikle görüntü işleme tekniklerine dayandığı için, yıkıcı olmayan seroloji veya moleküler yöntemlere kıyasla, non-invaziv hastalık tespit yöntemleri olarak düşünülebilir (Alatawi, 2022).

Hastalıklı bitkiler genellikle yapraklarda, saplarda, çiçeklerde veya meyvelerde belirgin izler veya lezyonlar gösterir. Her hastalık veya zararlı durum genellikle benzersiz bir görünür desen sunar ve bu, anormallikleri teşhis etmek için kullanılabilir. Bitki yaprakları, bitki hastalıklarını tanımlamak için başlıca kaynaktır ve hastalıkların çoğu, belirtilerini öncelikle yapraklarda göstermeye başlar. Bu durum, yapay zeka ve derin öğrenme algoritmalarının, yaprak görüntülerini analiz ederek hastalıkları tespit etme yeteneğinin altını çizer (Li ve ark., 2021).

1989'da, makine görüş görevlerinin karmaşıklığına bir çözüm olarak, Evrişimli Sinir Ağı (CNN) adı verilen yeni bir sinir ağı sınıfı ortaya çıktı. CNN'ler, özellikle görüntü tabanlı görevler için en etkili öğrenme algoritmalarından biri olarak kabul edilmeye başlandı (Ganatra ve ark., 2020). Evrişimli sinir ağlarının temel özelliği, görüntülerden özellikleri otomatik olarak çıkarma ve yüksek boyutlu verileri etkin bir şekilde işleme yetenekleridir. Bu özellikler, CNN'leri geniş bir uygulama alanında popüler hale getirmiştir (Wang, 2021).

Başlangıçta, derin öğrenme, bir 'karakutu' olarak algılanıyor ve bu algı, CNN'lerin gerçek zamanlı uygulamalarda kullanımını sınırlıyordu. Ancak, CNN'ler, el ile hazırlanmış özelliklere ihtiyaç duymadan doğrudan görüntülerden özellik çıkarabilen yapay zeka modelleridir. Bu özellik, bitki hastalığı sınıflandırma modellerini, geleneksel makine öğrenimi modellerine kıyasla daha etkili hale getirir. (Ganatra ve ark., 2020).

Pestisit kullanımı, bitkileri hastalıklardan veya enfeksiyonlardan koruyabilir ve böylece verimliliği artırabilir. Ancak pestisitlerin çevresel etkileri, hava, su, kuşlar, böcekler, toprak ve su altındaki canlılar üzerinde olumsuz etkilere neden olabilir (Ganatra ve ark., 2020). Bu nedenle, biyolojik düzeyde, organizmanın hızlı ve doğru bir şekilde belirlenmesi ve hastalığın ciddiyetinin kesin bir şekilde tahmin edilmesi, hastalıkları en aza indirmek ve doğru tedavi kararları almak için kritik öneme sahiptir. Bu bağlamda, bilgisayar zekası sistemleri, uzmanların rutin tanılamalarını desteklerken, hastalık desenlerini tanımlamak için güvenilir alternatifler sunabilir. Bu sorunun çözümünde umut vadeden bir yaklaşım, görüntü sınıflandırması için uygulanan derin öğrenme teknikleridir (Rezende, 2019).

Geleneksel olarak, tarım ve orman uzmanları hastalıkları sahada tanımlama rolünü üstlenmişlerdir ve çiftçiler de genellikle deneyimlerine dayanarak

meyve ağacı hastalıkları ve zararlılarını tanımlamışlardır. Bu yaklaşımlar, sadece subjektif olmakla kalmaz, aynı zamanda zaman alıcı, zahmetli ve genellikle verimsizdir. Deneyim eksikliği olan çiftçiler, tanı sürecinde yanlış değerlendirmeler yapabilir ve bu, ilaçların gereksiz ve yanlış kullanımına yol açabilir. Bu durum, ürün kalitesi ve verimliliği üzerinde olumsuz etkiler yaratırken, çevresel kirliliğe ve gereksiz ekonomik kayıplara neden olabilir (Li ve ark., 2021).

Bu zorluklara yanıt olarak, bitki hastalığı tanıma için görüntü işleme tekniklerinin kullanımı, son yıllarda önemli bir araştırma konusu haline gelmiştir. Görüntü tabanlı tanıma sistemleri, tarım uzmanları ve çiftçiler için objektif, hızlı ve etkili bir alternatif sunar. Bu sistemler, yapay zeka ve derin öğrenme teknolojilerini kullanarak, bitki hastalıklarını ve zararlılarını daha doğru ve hızlı bir şekilde tanımlayabilir. Bu yaklaşım, özellikle geniş çaplı tarım alanlarında veya uzman desteğinin sınırlı olduğu bölgelerde, hastalık yönetimi ve kontrolünü önemli ölçüde iyileştirebilir (Li ve ark., 2021).

Genomik ve proteomik alanlarda yaşanan önemli ilerlemeler, bu araştırma alanlarından büyük miktarda veri üretimiyle sonuçlanmıştır. Bilim insanları, genellikle geniş ölçekli genetik tarama ve genomik yaklaşımlarla ilgi çekici genleri ve proteinleri belirlemekteydi. Ancak, makine öğrenimi algoritmalarının gelişimi, bu süreci daha da ileriye taşımıştır. Bu algoritmalar, model oluşturma sürecini otomatikleştiren ve veriden öğrenerek açıkça programlama yapmadan içgörüler elde etmeyi sağlayan analitik yöntemler koleksiyonu olarak, bitki-patojen etkileşimlerinde yer alan genleri ve proteinleri tanımlamanın yanı sıra, enfekte yaprakların görüntülerinden bitki hastalıklarını sınıflandırmak için daha güçlü ve verimli araçlar sunmaktadır (Yang ve ark., 2017).

Dubey ve Jalal'ın çalışması (Dubey ve Jalal, 2012), bu teknolojik ilerlemelerin uygulamalarına dair somut bir örnek sunar. Bu çalışmada, lezyon bölgelerini segmente etmek için K-ortalama kümeleme yöntemi kullanılmış ve elma lekelerinin renk ve dokusal özelliklerini çıkarmak için küresel renk histogramı (GCH), renk uyumu vektörü (CCV), yerel ikili desen (LBP) ve tamamlanmış yerel ikili desen (CLBP) gibi yöntemler kullanılmıştır. İyileştirilmiş destek vektör makinesi (SVM) temelinde gerçekleştirilen bu çalışma, üç tür elma hastalığını %93'lük bir sınıflandırma doğruluğu ile tespit etmiş ve tanımlamıştır.

Chai ve arkadaşları tarafından yapılan bir çalışmada, dört domates yaprak hastalığı incelenmiştir: erken solgunluk, geç solgunluk, yaprak küfü ve yaprak lekesi. Bu çalışmada, domates yaprak lekesi görüntülerinden renk, dokusal ve şekil bilgilerini içeren 18 karakteristik parametre çıkarılmıştır. Adım adım ayırt edici analiz ve Bayesian Neural Network ayırt edici yöntemler kullanılarak bu parametreler incelenmiş ve sınıflandırma doğruluğu sırasıyla %94,71 ve %98,32'ye ulaşmıştır (Chai ve ark., 2010). Li ve He, çalışmalarında 5 farklı elma yaprak hastalığını - benekli dökülen hastalık, sarı yaprak hastalığı, yuvarlak leke hastalığı, mozaik hastalığı ve pas hastalığı - incelemiştir. Elma yaprak lekesi görüntülerinden renk, dokusal ve şekil özelliklerini içeren 8 parametre çıkararak, bu hastalıkları sınıflandırmak ve tanımak için BP sinir ağı modelini kullanmışlar ve ortalama tanıma doğruluğu %92,6'ya ulaşmıştır (Li ve He, 2010).

Guan ve arkadaşları ise pirinç yapraklarındaki hastalık lekelerine odaklanmışlardır. Çalışmalarında, morfoloji, renk ve dokusal özelliklerini içeren 63 parametre çıkararak, üç pirinç hastalığını - patlama, çizgi solgunluğu ve bakteriyel yaprak solgunluğu - sınıflandırmak ve tanımak için adım temelli ayırt edici analiz ve Bayesian Neural Network ayırt edici yöntemlerini uygulamışlardır. Bu yöntemlerle elde edilen tanıma doğruluğu %97,2'ye ulaşmıştır (Guan ve ark., 2010).

Son zamanlarda, görüntü tanıma ve sınıflandırmada üstün performansları nedeniyle, konvolüsyonel sinir ağları (CNN) tercih edilen yöntemler arasında öne çıkmıştır (Barbedo, 2018). CNN, görüntü işleme ve sınıflandırmada etkileyici sonuçlar elde etmiş ve bu alanda en popüler sınıflandırıcı haline gelmiştir (Kamilaris ve Prenafeta-Boldu, 2018). Özellikle, derin öğrenme yaklaşımları, bitki görüntü tanıma alanında yaprak damar desenlerine dayalı olarak ilk kez tanıtıldı (Grinblat ve ark., 2016). Bu alanda yapılan bir çalışmada, 3-6 katmanlı bir CNN kullanılarak beyaz fasulye, kırmızı fasulye ve soya fasulyesi gibi baklagil bitki türleri başarıyla sınıflandırılmıştır.

Mohanty ve arkadaşları, 14 tarım türü ve 26 tarım hastalığını tanımak için bir derin öğrenme modeli eğitmişlerdir. Bu eğitilen model, test setinde %99,35 gibi etkileyici bir doğruluk oranına ulaşmıştır (Mohanty ve ark., 2016). Benzer şekilde, Ma ve arkadaşları dört salatalık hastalığını (alt yaprak küfü, antraknoz, toz küfü ve hedef yaprak lekeleri) tanımak için derin bir CNN kullandılar ve tanıma doğruluğunu %93,4'e çıkardılar (Ma

ve ark., 2018). Kawasaki ve arkadaşları ise, salatalık yaprak hastalığını tanımak için CNN tabanlı bir sistem tanıttı ve bu sistem %94,9 doğruluk sağladı (Kawasaki ve ark., 2015).

CNN'lerin etkin bir şekilde eğitilmesi için genellikle büyük veri kümelerine (binlerce görüntüden oluşan) ihtiyaç duyulur. Ancak, bitki yaprak hastalığı tanıma konusunda bu kadar büyük ve çeşitli veri setlerine henüz erişim sağlanamamıştır. Bu durumda, transfer öğrenme yöntemi, CNN sınıflandırıcılarının bitki yaprak hastalığı tanıma için eğitilmesinde etkili bir çözüm sunmaktadır. Transfer öğrenme, önceden eğitilmiş CNN modellerini kullanarak, bu modelleri sıfırdan eğitmeye kıyasla daha küçük veri setleri üzerinde etkili bir şekilde uyarlayarak tekrar eğitmeyi mümkün kılar (Kessentini ve ark., 2019).

Özellikle, ImageNet gibi büyük veri setlerinde önceden eğitilmiş CNN modelleri, yaprak hastalığı tanıma için uyarlanabilir ve bu da sürecin etkinliğini artırır. Bu yaklaşım, bitki hastalıklarının tanınmasında karşılaşılan sınırlı veri seti sorununu çözmek için önemli bir strateji olarak öne çıkmaktadır. Derin öğrenme ve transfer öğrenme tekniklerinin birleşimi, bitki hastalıklarının daha doğru ve hızlı bir şekilde tanımlanmasını ve sınıflandırılmasını sağlar. Bu, özellikle tarım alanında hızlı karar verme ve etkili hastalık yönetimi için büyük bir avantaj sağlamaktadır.

Tarım alanında, özellikle bitki hastalığı tanıma konusunda, derin öğrenme (DL) tabanlı araştırmalar önemli ilerlemeler kaydetmiştir. Önceki çalışmalar (Kamilaris ve Prenafeta-Boldu, 2018), (Singh ve ark., 2018) bu alandaki araştırmaları özetlemiş, ancak DL ile birlikte uygulanan bazı yeni görselleştirme tekniklerini ve bitki hastalığı tanımlamada kullanılan ünlü DL modellerindeki gelişmeleri eksik bırakmıştır. Örneğin, (Singh ve ark., 2020) makalesi, bitki hastalığı tespiti için çeşitli görüntüleme tekniklerini sunmuş ve bu tekniklerin odak noktası olmuştur. Bu makalede, bitki hastalıklarının sınıflandırılması ve tanımlanması için SVM, K-ortalama ve KNN gibi temel teknikler ele alınmıştır.

(Saleem ve ark., 2019) makalesi ise, bitki hastalıklarını tespit etmek ve sınıflandırmak için uygulanan çeşitli geliştirilmiş ve değiştirilmiş DL mimarilerini sunmuştur. Bu çalışma, çeşitli bitki hastalıklarını görselleştirmek için kullanılan DL modelleri hakkında kapsamlı bir açıklama sağlamış, ancak hastalıkların erken tespiti ve küçük örneklem veri setleri üzerinde bitki hastalıklarını nasıl tespit edip sınıflandırılacağı konusunda yeterli bilgi vermemiştir.

Bu boşluk, gelecekteki arařtırmalara yol gösterici olabilir. Özellikle, küçük veri setlerine dayalı bitki hastalığı tanıma ve sınıflandırma, DL ve transfer öğrenme tekniklerinin birleşimini gerektiren bir alan olarak ön plana çıkıyor. (Ngugi ve ark., 2020) makalesinde ise, bu tür veri setlerinin etkili bir şekilde kullanımına odaklanarak, DL modellerinin küçük ölçekli veri setleri üzerinde nasıl uyarlanabileceği ve optimize edilebileceği ele alınmıştır. Bu çalışma, özellikle kaynak kısıtlılığı olan bölgelerde ve spesifik bitki türleri üzerinde yapılan arařtırmalar için önemli bir başvuru kaynağıdır.


Özetle, bu makale, bitki hastalıklarının tanımlanması ve sınıflandırılması alanında derin öğrenme (DL) ve konvolüsyonel sinir ağıları (CNN) gibi gelişmiş yapay zeka teknolojilerinin giderek artan önemini vurgulamaktadır. Geleneksel yöntemlerin sınırlılıkları göz önüne alındığında, bu teknolojik yaklaşımlar, tarım sektöründe hastalık tanıma ve yönetimi süreçlerini dönüştürme potansiyeline sahiptir. DL ve CNN'lerin, büyük veri setleri ve transfer öğrenme teknikleriyle birleştirilmesi, bu alandaki en son gelişmeleri temsil etmektedir ve tarım uzmanlarına, çiftçilere ve arařtırmacılara bitki hastalıklarını daha etkili bir şekilde tanıma ve sınıflandırma imkânı sunmaktadır. Bu teknolojik ilerlemeler, bitki hastalıklarının erken teşhisi, verimliliğin artırılması ve sürdürülebilir tarım uygulamalarının desteklenmesi açısından önemli bir adımdır. Makalemiz, bu alanda yapılan mevcut çalışmalarını ele alarak, gelecekteki arařtırmalar için bir temel oluşturmakta ve bu teknolojilerin tarım sektöründeki uygulanabilirliği ve potansiyelini geniş bir perspektifle sunmaktadır.

Materyal ve Metot

Bu arařtırma, bitki hastalıklarının tespiti konusunda önemli bir adım atmayı amaçlamakta ve bu amaçla 'Plant Diseases Dataset' adlı geniş bir veri setini kullanmaktadır. Bu veri seti, farklı bitki türlerine ait geniş bir yelpazede sağlıklı ve hastalıklı yaprak örneklerini içermekte olup, bu örneklerin her biri bitki hastalıklarının tespiti için hayati öneme sahiptir. Arařtırmanın temelini oluşturan RESNET adındaki Convolutional Neural Network (CNN) modeli, bu zengin veri setini kullanarak bitki yapraklarının görüntülerini analiz eder ve bu analiz sonucunda sağlıklı ile hastalıklı yaprakları birbirinden ayırt edebilmektedir. Modelin geliştirilmesi sürecinde, yapay zeka ve makine öğrenimi tekniklerinden faydalanılmış ve model, bitki hastalıklarının çeşitli türlerini başarıyla tanıyabilme kapasitesine sahip hale getirilmiştir.

Modelin eğitimi sırasında, veri setinde yer alan farklı bitki türleri ve hastalıkların detaylı analizleri yapılmış, bu sayede modelin geniş bir hastalık yelpazesini tanıma ve sınıflandırma yeteneği geliştirilmiştir. RESNET modeli, yapay zeka algoritmalarının gücünü kullanarak, bitki yapraklarının renk, doku ve diğer görsel özelliklerini değerlendirerek sağlıklı ve hastalıklı yaprakları ayırt etme konusunda yüksek doğruluk oranlarına ulaşmıştır.

Modelin test edilmesi sırasında elde edilen sonuçlar, bitki hastalıklarının tespiti konusunda modelin yüksek başarı gösterdiğini ortaya koymuştur. Doğruluk oranları, modelin farklı bitki türleri ve hastalıklar üzerindeki etkinliğini göstermektedir. Bu başarı, tarım sektöründe hastalıkların erken tespiti ve müdahalesi konusunda büyük bir potansiyel sunmaktadır.




Resim 1 - Örnek Veriler

Resim 1, bitki sağlığı araştırmaları ve derin öğrenme modellemeleri için hayati öneme sahip olan geniş ve çeşitli yaprak görüntülerinin bir örneğini sergilemektedir. Her bir yaprak imajı, bitkilerin hastalıklı ve sağlıklı durumlarını temsil eden geniş bir veri yelpazesini yansıtmakta bu da tarımsal hastalıkların teşhisinde ve sınıflandırmasında kullanılan yapay zeka sistemlerinin doğruluğunu artırmak için kritik veriler sağlar. Bu görüntüler, bitki patolojisi ve veri bilimi disiplinlerinin kesişiminde, hastalık belirtilerinin çeşitli görünümünü ve evrelerini kapsayan bir spektrum kapsar. Yaprakların renk değişimleri, desenler ve dokusal farklılıklar, bitki hastalıklarının erken teşhisi için algoritmik modellerin eğitilmesinde kullanılır. Bu veri seti, algoritmaların daha geniş ve gerçek dünya koşullarına uyum sağlamasını sağlayarak, bitki sağlığı yönetiminde

önemli bir rol oynar ve tarımsal üretimde verimliliği artırmaya yönelik stratejilerin geliştirilmesine katkıda bulunur.

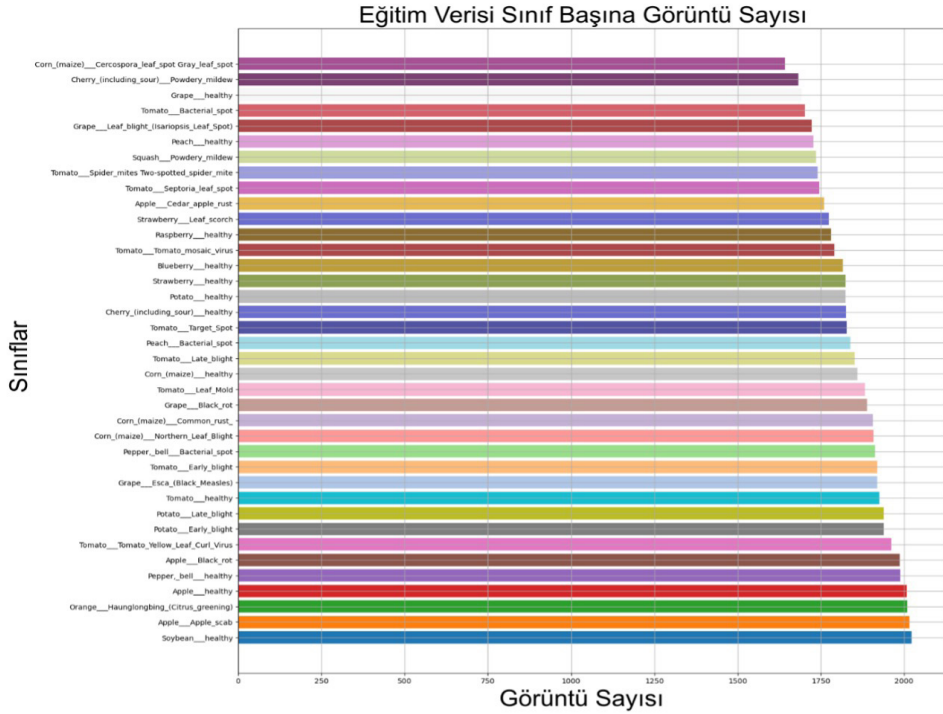


Resim 2 - Örnek Veriler



Resim 3 - Örnek Veriler

Resim 2 ve Resim 3, tarımsal bitki hastalıklarının teşhisinde kullanılan görüntü işleme ve sınıflandırma tekniklerinin hassasiyetini artıran zengin veri örneklerini sergilemektedir. Resim 2'de, asma yaprağındaki çeşitli hastalık belirtileri gösterilirken, Resim 3 mısır yapraklarındaki sağlıklı ve hastalıklı durumları betimlemektedir. Bu görseller, hastalık tespiti için gerekli görsel farklılıkları ve detayları barındırmakta olup, yapay zeka algoritmalarının eğitimi için temel oluşturmaktadır. Her iki resimde, modelimizin, belirli hastalıkları tanıma ve sınıflandırma kabiliyetinin doğruluğunu test etmek için kullanılmıştır.



Resim 4 - Veri Seti Dağılımı

Resim 4’te de görüldüğü üzere veri setimiz, mısır ve elma gibi çeşitli tarım ürünlerinin yapraklarına ait geniş bir görüntü koleksiyonunu içermekte ve hem sağlıklı hem de hastalıklı durumları kapsamaktadır. Mısır yapraklarında görülen Northern Leaf Blight, Cercospora leaf spot ve Common rust hastalıkları, bitki patolojisi alanında önemli araştırma konularındandır ve görüntü setimiz bu hastalıkların teşhisinde kullanılan algoritmaların eğitiminde değerli bir kaynak olarak hizmet etmektedir. Elma yapraklarında ise Apple scab, Black rot ve Cedar apple rust hastalıkları, derin öğrenme modellerinin doğruluk ve hassasiyetini artırmak için kullanılan zorlu vakaları temsil eder. Üzüm yapraklarındaki sağlıklı örnekler ile Leaf blight, Black rot ve Esca (Black Measles) hastalıkları arasındaki kontrast, yapay zeka sistemlerinin bitki sağlığı yönetimindeki karar verme süreçlerini desteklemedeki kritik rolünü vurgulamaktadır. Bu görüntüler, bitki hastalıklarının erken teşhisi ve tedavisine yönelik geliştirilen çözümlerin doğruluğunu artırmak amacıyla zengin veri ve görüntü işleme tekniklerinin kullanıldığı bir altyapıyı temsil eder.

"Plant Diseases Dataset" içerisinde gerçekleştirilen kapsamlı veri toplama ve düzenleme çalışmaları sonucunda, Domates, Mısır, Üzüm ve diğer önemli tarım ürünlerine ait bitki hastalıklarının dengeli bir dağılımına ulaşılmıştır. Gösterge niteliğindeki bu daire grafik, sağlıklı bitki yapraklarından Turunçgil yeşillenme hastalığı (Haunglongbing) gibi spesifik hastalıklara kadar geniş bir yelpazede, veri setimizin ne kadar dengeli ve kapsamlı olduğunu gözler önüne sermektedir; bu da hastalık tespit modelimizin doğruluğunu ve güvenilirliğini önemli ölçüde artırarak tarımsal araştırmalarda kullanılabilirliğini pekiştirmektedir.

Sonuç olarak, bu araştırma, bitki sağlığı ve hastalık tespiti konusunda yapay zeka ve makine öğreniminin potansiyelini ortaya koymaktadır. RESNET modelinin geliştirilmesi ve başarılı bir şekilde uygulanması, tarım sektöründe verimliliği ve sürdürülebilirliği artırma yolunda önemli bir adımdır.

Model

Evrişimsel Sinir Ağları (CNN), görsel algılama görevlerinde öne çıkan derin öğrenme modellerinin bir alt kümesidir. CNN'ler, görüntülerdeki karmaşık yapıları tanıma ve sınıflandırma konusunda üstün performans sergilemeleriyle bilinir. Bu başarının temelinde, CNN'lerin bir görüntüdeki yerel özellikleri öğrenme kabiliyeti yatar. Bu yerel özellikler, genellikle kenarlar, köşeler ve doku gibi görsel öğelerdir.

Evrişimsel işlem, bir görüntüyü temsil eden giriş matrisi üzerinde bir filtre matrisi uygulanarak gerçekleşir. Bu filtre, belirli bir özelliği yakalamak için tasarlanmıştır ve görüntü üzerinde kaydırılarak her bölgedeki özelliklerin aktivasyonunu ölçer. Matematiksel olarak, bir (F) filtresi ve bir (I) görüntüsü için evrişimsel sonucu (S) şu şekilde hesaplanır:

$$S(i, j) = (I * F)(i, j) = \sum_{m=0}^{m-1} \sum_{n=0}^{n-1} I(i + m, j + n) * F(m, n) \quad (1)$$

Aktivasyon fonksiyonunun uygulanması, filtre boyutuna karşılık gelen bir pencerenin tüm giriş matrisi üzerinde hareket ettirilmesiyle gerçekleştirilir ve bu, aktivasyon haritası olarak bilinen yeni bir matrisin oluşturulmasını sağlar. Bu özelliklerin non-lineer bir biçimde haritalanmasını sağlayan ReLU (Düzeltilmiş Lineer Birim) aktivasyon fonksiyonu, evrişimsel işlemi takiben genellikle uygulanır ve matematiksel olarak şu şekilde ifade edilir:

$$f(x) = \max(0, x) \quad (2)$$

ReLU, negatif değerleri sıfırlarken pozitif değerleri değiştirmeden bırakır. Bu basit işlem, modelin negatif değerleri görmezden gelmesini sağlar ve non-linear bir aktivasyon sağlamak için gereklidir. Ayrıca, modelin lineer olmayan özellikleri öğrenmesine yardımcı olur ve aktivasyon haritasındaki negatif değerlerin baskılanmasına olanak tanır.

Havuzlama (Pooling), aktivasyon haritasının boyutunu küçültmek ve hesaplama karmaşıklığını azaltırken, modelin öğrendiği özelliklerin konumsal değişkenliklere karşı dayanıklı olmasını sağlamak için kullanılır. Max-pooling, en yaygın havuzlama yöntemlerinden biridir ve belirli bir pencere boyutu içindeki maksimum değeri seçerek bu bölgeyi temsil eder; örneğin, 2x2'lik bir max-pooling, her 4 piksellik bölgeden en büyük değeri seçer. Havuzlama katmanı, konvolüsyondan gelen özellik haritalarının boyutunu azaltarak hesaplama maliyetini düşürür ve aynı zamanda modelin konumsal değişkenliklere karşı dayanıklılığını artırır. Matematiksel olarak, bir (P) havuzlama işlemi şöyle tanımlanabilir:

$$P(i, j) = S(i * stride + k, j * stride + l) \quad (3)$$

Burada (stride), havuzlama penceresinin kaydırma miktarını; (k) ve (l), ise havuzlama penceresinin boyutunu ifade eder. Havuzlama işlemi, her pencere içindeki maksimum değeri seçerek boyutu azaltır.

Son olarak, tamamen bağlı (fully connected) katmanlar, evrimsel ve havuzlama katmanlarının çıktılarını alır ve ağın son sınıflandırma işlemini gerçekleştirir. Bu katmanda, her nöron önceki katmandaki tüm nöronlara bağlıdır ve bu yapının sonucunda, ağın eğitim verileri üzerinde öğrendiği özellikler kullanılarak giriş görüntüsünün hangi sınıfa ait olduğu belirlenir.

ResNet

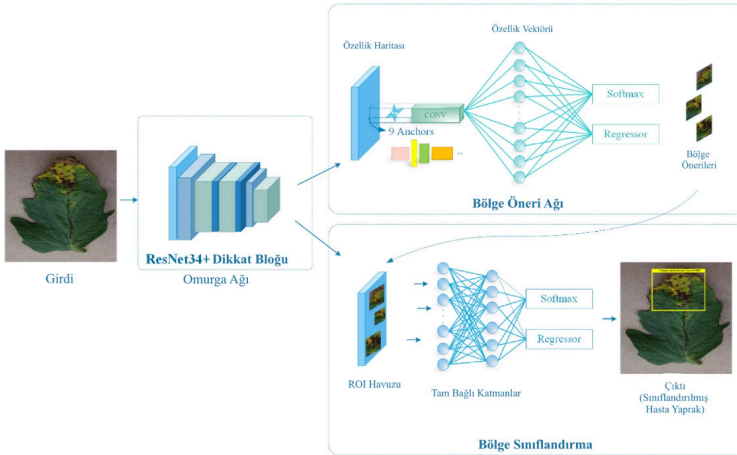
Residual Networks (ResNet), derin sinir ağlarındaki eğitim zorluklarını aşmak için tasarlanmış yenilikçi bir mimaridir. Derin öğrenme mimarileri, katman sayısı arttıkça karşılaşılan 'kaybolan gradyan' sorununun üstesinden gelmek için ResNet, artık öğrenme (residual learning) yaklaşımını benimsemiştir. Bu yaklaşım, katman girdilerini doğrudan çıktılara ekleyerek ağın daha derin katmanlarında öğrenmeyi kolaylaştırmayı amaçlar.

ResNet'in temel bileşeni, birimler arası atlamalı bağlantılardır (skip connections). Bu bağlantılar, aktivasyonları birkaç katman ötesine taşıyarak, ağın derin bölgelerine bilgi akışını düzgün bir şekilde sürdürmesini sağlar.

Atılan bağlantılar, ağı eğitimi sırasında, önemli bilgilerin kaybolmasını önleyerek daha karmaşık öğrenme görevlerinin üstesinden gelmesine yardımcı olur.

ResNet mimarisinin katmanlar arasındaki fonksiyonel ilişki, $(F(x) + x)$ olarak ifade edilir. Burada (x) giriş aktivasyonunu, $(F(x))$ ise katman tarafından öğrenilen residual fonksiyonunu temsil eder. Bu yapı, öğrenilen fonksiyonun sıfıra yakın bir hata ile optimize edilmesi gerektiğinde dahi, girişin orijinal sinyalini koruyarak ağı eğitilmesine imkân tanır.

Mühendislik ve bilimsel çalışmalarda ResNet'in kullanımı, görsel tanıma ve sınıflandırma görevlerinde önemli iyileştirmeler sağlamıştır. Özellikle bitki hastalıkları tespiti gibi alanlarda, ResNet kullanılarak elde edilen sonuçlar, hastalık belirtilerinin doğru bir şekilde tanınmasında ve sınıflandırılmasında önemli ilerlemeler sunmuştur. Bu ilerlemeler, erken teşhis ve müdahaledeki doğruluğu artırarak, tarımsal üretimdeki kayıpları azaltma potansiyeline sahiptir. Model, öncelikle girdi olarak alınan yaprak görüntüsünü ResNet34 destekli bir omurga ağı (backbone network) üzerinden geçirerek özellik haritalarını (feature maps) oluşturur. Dikkat bloğu, modelin odaklanması gereken alanları belirleyerek önemli özellikleri vurgular ve gürültünün etkisini azaltır. Ardından, bölge öneri ağı (region proposal network, RPN), bu özellik haritalarını kullanarak ilgi alanlarını (ROI) belirleyen çeşitli aday bölgeleri önerir. Her bir aday bölge, ROI havuzlama işleminden geçerek boyutunun normalleştirilmesi sağlanır ve tam bağlantılı katmanlara (fully connected layers) iletilir.



Resim 6 - ResNet Çalışma Mantığı (Nawaz, 2022)

Bu katmanlar, sınıflandırma (Softmax) ve regresyon analizleri yaparak, hastalıklı yaprakların yerelizasyonunu ve sınıflandırmasının nasıl gerçekleştiği Resim 6'da görmekteyiz. Modelin çıktısı, lokalize edilmiş ve sınıflandırılmış hastalıklı yaprağı gösterir, böylece modelin hem hastalığı tespit etme hem de bunu yaprak üzerinde doğru bölgeye yerleştirme kabiliyeti ortaya konulur. Sonuç olarak, ResNet mimarisi, derin öğrenme algoritmalarının performansını artırmak ve daha derin ağ yapılarını eğitmek için kritik bir gelişmedir. Bu mimari, gelişmiş görsel algılama yetenekleri sayesinde, otomatik tanıma ve analiz sistemlerinin geliştirilmesinde yeni ufuklar açmaktadır.

Neden ResNet?

ResNet mimarisinin tercih edilmesinin altında yatan nedenler, onun derin öğrenme modelleri arasında öne çıkan performansı ve sağladığı benzersiz avantajlardır. Derin sinir ağları geleneksel olarak katman sayısı arttıkça eğitimde karşılaşılan kaybolan gradyan problemiyle mücadele ederken, ResNet bu problemi atlamalı bağlantılar (skip connections) kullanarak çözümlenmiştir. Bu bağlantılar sayesinde, ağın daha derin katmanlarına bilgi akışı daha verimli bir şekilde sürdürülebilir ve daha derin ağ yapıları başarıyla eğitilebilir. Bu özellikler, ResNet'in karmaşık veri setlerinde ve özellikle de çok çeşitli ve büyük görsel veri gerektiren bitki hastalıkları tespiti gibi alanlarda tercih edilmesinin ana sebeplerindedir. ResNet, öğrenme kapasitesini maksimize ederken hesaplama yükünü optimize eder ve bu da onu geniş kapsamlı görsel algılama görevleri için ideal bir seçim haline getirir. Ayrıca, mevcut literatürde ResNet tabanlı modellerin başarıları, bu mimarinin çeşitli görsel tanıma görevlerindeki yüksek performansını ve genelleştirilebilirliğini kanıtlamıştır. Bu nedenlerle, ResNet'in Plant Diseases Dataset üzerinde yüksek doğrulukla hastalık tespiti yapma potansiyeli, onu bu projede kullanma kararı için güçlü bir aday yapmaktadır.

Modelin Eğitim Süreci ve Yapısı, Veri Hazırlığı

Bitki hastalıkları tespiti için ResNet mimarisi kullanılarak geliştirilen modelimiz, geniş ve çeşitlendirilmiş bir veri setinin hazırlanması ve işlenmesi süreçlerini kapsamaktadır. Modelin eğitim süreci, Keras kütüphanesinin sağladığı ImageDataGenerator sınıfının sağladığı güçlü veri artırma (data augmentation) yeteneklerini kullanarak gerçekleştirilmektedir. Bu sınıf, modelin eğitimi sırasında gerçek zamanlı olarak görüntü döndürme, ölçeklendirme, kaydırma ve diğer

dönüşümleri uygulayarak, modelin genelleştirme yeteneğini artırmakta ve olası aşırı uyum (overfitting) sorunlarını azaltmaktadır. Özellikle bitki hastalıkları tespiti bağlamında, modelin farklı bitki türlerine ait çeşitli hastalıkların görsellerini tanıyabilmesi için, gelişmiş veri artırma teknikleri kullanılmıştır. Bu teknikler sayesinde, model farklı ışık koşulları, perspektifler ve görüntü bozulmaları altında bile bitki hastalıklarını doğru bir şekilde sınıflandırabilme yeteneğine sahip hale getirilmiştir.

initDataSets() fonksiyonu, modelin ihtiyaç duyduğu veri setlerini dinamik olarak hazırlar ve işler. ImageDataGenerator ile entegre çalışan bu fonksiyon, belirli bir dizindeki veriyi alır ve model eğitimi için kullanılacak şekilde düzenler. Bu yaklaşım, özellikle büyük veri setleri ile çalışırken, bellek kullanımını optimize etmekte ve disk okuma/yazma işlemlerini minimuma indirmekte büyük bir etkinlik göstermektedir. Sonuç olarak, ResNet tabanlı modelimiz, bu kapsamlı veri hazırlığı ve artırma teknikleri ile, bitki hastalıkları tespiti konusunda güçlü bir performans sergilemek için tasarlanmıştır. Model, karmaşık veri setleri üzerinde eğitilerek, tarımsal araştırmalar için değerli ve doğru tespitler yapabilme kapasitesine ulaşmıştır.

Modelin Özelleştirilmesi

Bitki hastalığı tespiti için özelleştirilen ResNet modeli, 'getAllForTraining()' fonksiyonu ile çeşitli geri çağırma fonksiyonları ve optimizasyon ayarlarını içerecek şekilde geliştirilmiştir. 'ReduceLROnPlateau' geri çağırma fonksiyonu, bir metrikte ilerleme kaydedilmediğinde öğrenme hızını otomatik olarak azaltır, böylece modelin eğitimi sırasında yerel minimumlara takılmaktan kaçınarak global minimuma verimli bir şekilde ulaşması sağlanır. 'ReduceLROnPlateau' hakkında daha fazla bilgi edinmek için Keras'ın resmi belgelerini ziyaret edebilirsiniz (URL 1).

Aynı zamanda, eğitimin verimliliğini ve zaman yönetimini optimize etmek adına 'EarlyStopping' geri çağırma fonksiyonu kullanılır. Belirli bir metrik üzerinde bir süre boyunca ilerleme gözlemlenmediğinde eğitimin otomatik olarak durdurulmasını sağlar. Bu yaklaşım, modelin aşırı uyuma (overfitting) karşı korunmasına yardımcı olur (URL 1). Bu geri çağırma fonksiyonlarının kullanımı, derin öğrenme modellerinin eğitim sürecinde sık karşılaşılan plato bölgelerinde ilerleme sağlamada önemli bir rol oynar ve öğrenme hızının dinamik ayarlanması sayesinde modelin ağırlıklarının daha ince ayarlanmasına imkan tanır (URL 2 – URL 3). Bu tekniklerin uygulanması, bitki hastalıkları tespiti gibi karmaşık görevlerde modelin

performansını artırarak daha doğru sonuçlar alınmasını sağlar. Modelin 'updateBaseModel()' fonksiyonu ile MobileNet mimarisi, başlangıçta genel amaçlı bir yapı iken belirli görevlere göre özelleştirilmek üzere tasarlanmıştır. MobileNet, hafif yapısı ve düşük hesaplama gereksinimi ile bilinir. Bu yapı, derinliklerine ayrılabilir evrişimler (depthwise separable convolutions) kullanarak hafif ve yüksek performanslı derin sinir ağları oluşturur. MobileNet'in bu özellikleri, özellikle düşük güç ve düşük gecikme gerektiren uygulamalarda etkili bir performans sergilemesini sağlar. MobileNet'in genel yapısı ve bu yapının nasıl özelleştirilebileceği, MobileNet'in mimari detayları ile ilgili yapılan araştırmalarda daha ayrıntılı olarak incelenmiştir (ar5iv.org, 2017) (URL 4). Bu özellikler, bitki hastalıklarının sınıflandırılması gibi spesifik görevlerde MobileNet'in tercih edilmesini sağlar.

Model optimizasyonunda kullanılan Adam optimizasyon algoritması, öğrenme oranının adaptif bir şekilde ayarlanması ve momentumun birleştirilmesi prensiplerine dayanır. Adam, AdaGrad ve RMSProp algoritmalarının en iyi özelliklerini birleştirerek, gürültülü problemlerde ve seyrek gradyanlarda etkili bir optimizasyon sağlar. Genel olarak, Adam algoritmasının varsayılan ayarları (öğrenme oranı=0.001, beta1=0.9, beta2=0.999, epsilon=1e-08) çoğu probleme iyi uyum sağlar ve derin öğrenme modellerinin eğitiminde yaygın olarak tercih edilir. Adam algoritması, özellikle karmaşık görevlerde, bitki hastalığı tespiti gibi alanlarda, modelin hızlı ve stabil bir şekilde yakınsamasını sağlayarak yüksek doğrulukla sınıflandırma yapılmasına olanak tanır (MachineLearningMastery) (URL 5). Bu teknik ve stratejilerin birleşimi, bitki hastalıklarının tespiti için ResNet tabanlı modelin başarısını artıran faktörlerdir. Özellikle tarımsal araştırmalar ve gerçek zamanlı uygulamalar göz önünde bulundurulduğunda, bu yaklaşım, hastalık tespitinde yüksek doğruluk ve verimlilik sağlamak için kritik öneme sahiptir.

Bitki Hastalığı Tespiti




| <i>Resim 7 - Bitki Tipi Seçme</i> | <i>Resim 8 - Hastalık fotoğrafı çekme</i> |
|---|---|
| <p>Uygulamamızın arayüzünde sunduğumuz zengin bitki kütüphanemizden tarım ürününüzü seçmeniz beklenir. Bu seçim, yapay zeka destekli sistemimizin, tarlanızın özgün ihtiyaçlarına özel çözümler üretmesinin temelini oluşturur. Seçeceğiniz ürün tipi, alacağınız teşhislerin ve önerilerin kişiselleştirilmesinde kritik rol oynar. Kullanıcı Dostu Arayüz: Yalnızca bir dokunuşla, domateslerden biberlere, patlıcanlardan kabaklara kadar geniş bir yelpazede ürününüzü seçin.</p> <ul style="list-style-type: none">- Hassas Teşhis: Doğru bitki türü seçimi, algoritmanın verimliliğini ve teşhis hassasiyetini artırır.- Çoklu Ürün Desteği: Çeşitlilik bizim için değerli, birden fazla ürün türü için aynı hassasiyetle çalışma olanağımız var. <p>Her bir seçim, tarımın sürdürülebilirliğini ve ürün verimliliğini destekleyen daha geniş bir yolculuğun ilk adımımızdır. 'Ürün Tipi Seçme' ile başlayan bu yolculuk, yapay zekamızın sunduğu akıllı teşhislerle devam eder ve sizi tarımınızda yeni ufuklara taşır.</p> | <p>Makalemizin bu bölümünde, tarım alanlarının sağlık durumunun izlenmesi ve korunması sürecindeki önemli bir adım olan uygulamamızın teşhis özelliğine değineceğiz. Kullanıcıların seçtikleri ürün türüne ait bitkilerdeki hastalık belirtilerini etkin bir şekilde tespit etmelerini sağlamak amacıyla, 'Hastalık Fotoğrafı Çekme' özelliği geliştirilmiştir. Bu özellik, kullanıcıların akıllı telefonlarının kamerası aracılığıyla, bitkilerindeki herhangi bir hastalık izi, leke veya anormalliği uygulamamıza hızla aktarmalarına olanak tanır.</p> <ul style="list-style-type: none">- Fotoğraf Çekme: Kullanıcılar, bitkilerini en net şekilde gösteren fotoğrafları çekebilmek için kamera özelliğini kullanır. Bu, hastalık belirtilerinin doğru bir şekilde kaydedilmesi için temel bir adımdır.- Akıllı Tarama: Uygulamamız, çekilen fotoğrafı otomatik olarak analiz eder ve potansiyel sağlık sorunlarını belirler. Bu analiz, gelişmiş görüntü işleme algoritmaları kullanılarak gerçekleştirilir.- Hızlı Sonuçlar: Fotoğraf çekildikten hemen sonra, yapay zeka destekli algoritmamızın hızlı bir şekilde işlem yapması sağlanır. Bu, hastalık teşhis sürecinde etkinliği artırır. <p>Bu özellik sayesinde, çiftçiler ve tarım profesyonelleri, hastalıkların yayılmasını önlemede kritik öneme sahip zaman kazanırlar ve bitkilerinin sağlığını koruma altına alırlar. Çekilen resimler, bulut tabanlı sistemimizde anında işlenerek, hastalığın türüne dair kesin bilgiler sunar. Bu süreç, sağlıklı ürünlerin elde edilmesi ve verimli hasatlar için gereken bilgiye ulaşılmasında önemli bir rehberlik rolü oynar.</p> |



| Resim 9 - Anında Teşhisi Görme | Resim 10 - Tedavi Önerileri Alma |
|---|---|
| <p>Makalemizin bu kısmında, bitkilerdeki hastalıkların hızlı ve etkin bir şekilde tanımlanmasını olanak tanıyan ‘Anında Teşhisi Görün’ özelliğimizi inceleyeceğiz. Bu özellik, kullanıcılar tarafından çekilen resimlerin yapay zeka destekli derin öğrenme algoritmalarımızla analiz edilmesi sürecini temel alır. Bu süreç, teşhisin hem hassas hem de hızlı bir şekilde yapılmasını mümkün kılar, böylece hastalıkların erken teşhisi artık sadece bir dokunuş uzaklığında bulunur.</p> <ul style="list-style-type: none"> - Güvenilir Teşhis: Uygulamamız, gönderilen resimleri anında işleyerek, yüksek doğruluk oranıyla hastalığın türünü belirler. Bu, bitki sağlığını yönetimde önemli bir adımdır. - Detaylı Bilgiler: Teşhis edilen hastalık hakkında detaylı bilgiler, olası nedenleri ve etmenleri kullanıcılarına sunulur. Bu bilgiler, hastalıkların daha iyi anlaşılmasını ve yönetilmesini sağlar. - Anlaşılır Sonuçlar: Teşhis sonuçları, hastalığın olasılık yüzdesi ile birlikte sunulur, durumun ciddiyeti hakkında net bir fikir verir. <p>Bu etkileşimli teşhis süreci, tarım uzmanları ve çiftçilerin karşılaştıkları sorunları hızla anlamlarını ve gerekli önlemleri zamanında alabilmelerini sağlar. ‘Anında Teşhisi Görün’ özelliği, bitki sağlığını izleme ve yönetme süreçlerini daha şeffaf ve kontrol edilebilir hale getirir. Bu özellik, bitki sağlığını korumak için gerekli tüm bilgileri kullanıcıların parmaklarının ucuna getirerek, tarım alanında yeni bir dönemin kapılarını aralamaktadır.</p> | <p>Yapay zekâ temelli teşhisin ardından, çözüm ve iyileşme sürecinin başlamasıyla, ‘Tedavi Önerileri Alın’ adımı devreye girer. Bu aşama, teşhis edilen hastalığın türüne ve şiddetine göre özelleştirilmiş tedavi yöntemleri sunar. Uygulamamız, bitkinin karşılaştığı özgül problemlere yönelik en etkili tedavi yöntemlerini, hem kültürel hem de kimyasal mücadele seçeneklerini ve gerektiğinde ilaç önerilerini içermektedir.</p> <ul style="list-style-type: none"> - Kültürel Mücadele: Bu yaklaşım, bitki sağlığını doğal yollarla koruma yöntemleri hakkında bilgilendirme yapar ve sürdürülebilir tarım pratiklerine odaklanır. - Kimyasal Mücadele: Gerekli durumlarda, etkili ve güvenli pestisit kullanımına ilişkin yönergeler sunar. Bu, zararlı organizmalarla mücadelede kritik bir rol oynar. - İlaç Önerisi: Hastalığın tedavisinde kullanılacak ilaçlar hakkında net ve anlaşılır öneriler sağlar. Bu, hastalıkların yönetiminde bilinçli kararlar almayı kolaylaştırır. <p>Uygulamanın bu özelliği, tarım pratiğinde bilinçli ve etkin müdahaleler için gerekli bilgileri sunarak bitki sağlığını koruma ve ürün verimliliğini artırmada güçlü bir yardımcıdır. Tedavi önerileri, sürdürülebilir tarım anlayışına uygun, bitkilerin hastalıklardan korunmasını ve güçlenmesini sağlayacak çözümleri içerir. ‘Tedavi Önerileri Alın’ özelliği, bitki sağlığının en üst düzeye çıkarılmasında önemli bir araç olarak öne çıkar.</p> |

Çalışma Mantığı



Resim 11 – Uygulama Çalışma Sistemi

Resim 11’de uygulamamızın çalışma sistemini göstermektedir. Bitki sağlığını izlemek ve yönetmek için modern teknolojilerin entegrasyonunu kapsamlı bir şekilde ele alır. Kullanıcı, akıllı telefon aracılığıyla bitkisine yönelik sorunları tespit etmek için mobil uygulamamızı kullanır. Uygulama, yapay zeka destekli görüntü işleme algoritmaları kullanarak bitki yapraklarındaki belirtileri analiz eder ve potansiyel hastalıkları tanımlar. Bu süreç, bir yapay sinir ağı tarafından yönetilir ve tanı konulan hastalığa ilişkin bilgileri ve yönetim önerilerini kullanıcıya sunar. Sistem, tarım uzmanları ve hobi bahçıvanları için kolaylıkla erişilebilir, etkileşimli ve eğitici bir kaynak olarak hizmet ederken, bitki sağlığı izleme ve hastalık teşhisinde dijital dönüşümün önemini vurgular.



Resim 12 – Tahmin Doğruluk Oranı %100



Resim 13 – Tahmin Doğruluk Oranı %98




Resim 14 – Tahmin Doğruluk Oranı %100



Resim 15 – Tahmin
Doğruluk Oranı %100



Resim 16 – Tahmin
Doğruluk Oranı %95



Resim 17 – Tahmin
Doğruluk Oranı %100

Modelimiz, Resim 12-17’de gözüktüğü üzere, geniş çaplı bitki hastalıkları sınıflandırma görevinde yüksek doğruluk oranları elde ederek, tarımsal hastalık teşhisinde yapay zekanın potansiyelini sergilemektedir. Örneğin şeftali, biber ve yaban mersini gibi çeşitli bitki türlerine ait yaprak örneklerinin incelenmesi, modelimizin hem sağlıklı bitki durumlarını hem de hastalıklı belirtileri ayırt edebilme kabiliyetini doğrulamaktadır. Her bir teşhis, bitkilerin semptomlarını yüksek doğrulukla tanıma ve sınıflandırma becerisini kanıtlar niteliktedir. Bu, modelin eğitim ve validasyon süreçlerinin, gerçek dünya tarımsal verileri üzerinde ne kadar etkili olduğunu göstermektedir. Elde edilen sonuçlar, bitki hastalıkları teşhisinde erken ve doğru müdahale stratejileri geliştirmek için zemin hazırlamakta, böylece tarımsal üretimde verimliliği artırmak ve kayıpları azaltmak için güçlü bir temel oluşturmaktadır. Bu çalışma, yapay zeka teknolojilerinin tarım sektöründe sağlayabileceği katma değeri ve önemi ortaya koymakta, bilim ve teknolojinin bu alandaki birleşimini daha da ileriye taşıma potansiyeline işaret etmektedir.

Veri Yükleme ve Ön İşleme

Bitki hastalığı tespiti projesindeki veri yükleme ve ön işleme süreci, fotoğrafın analize hazır bir formata dönüştürülmesini içerir. Öncelikle, verilen fotoğraf ya bir dosya yolundan alınır ya da doğrudan bir görüntü matrisi olarak işlenir. RGB formatına dönüştürme işlemi, görüntünün renk kanallarının uygun bir şekilde model tarafından işlenmesini sağlar. Yüz tespiti için OpenCV kütüphanesinin Haar özellik tabanlı sınıflandırıcısı tercih edilir, ancak bitki hastalığı tespiti kontekstinde bu, bitki yaprakları üzerindeki karakteristik özellikleri tanımlamak için uyarlanmış özel

bir sınıflandırıcı ile değiştirilebilir. Görüntü, modelin girdi boyutu olan örneğin 256x256 piksel gibi bir boyuta yeniden ölçeklendirilir.

Modelin verimli bir şekilde işlemlerini sağlamak için piksel değerleri [0, 1] aralığında ölçeklenir. Bu ön işlemden geçen bitki yaprağı görüntüsü, eğitilmiş derin öğrenme modeline beslenir ve modelin tahmini, hastalık durumunun olasılık dağılımı olarak geri döner. Tahminler, orijinal görüntü ile birlikte görselleştirilerek, modelin her bir hastalık sınıfına olan güvenini yüzdelik değerlerle sunan bir çubuk grafiği aracılığıyla sergilenir.

Projede, farklı bitki hastalıklarının sınıflandırma başarı oranları detaylı bir şekilde incelenir ve hangi hastalığın daha stabil ve güvenilir sonuçlar verdiği için bir analiz yapılır. Performans değerlendirmesinde, ROC eğrisi kritik bir araç olarak kullanılır. ROC eğrisi, modelin farklı sınıflandırma eşik değerlerindeki duyarlılığını ve doğruluğunu görselleştirir, böylece modelin belirli bir kesme noktasında ne kadar hassas olduğu belirlenebilir. Bu analiz, modelin sınıflandırma eşiklerinde nasıl tepki verdiğini anlamak için önemlidir ve eşik değeri, bir yaprağın belirli bir hastalık sınıfına ait olup olmadığına karar vermek için kritik bir parametredir. Bu süreç, bitki hastalığı tespiti projesinin başarısını optimize etmek için hayati öneme sahiptir ve derin öğrenme tabanlı tanı sistemlerinin tarımsal uygulamalardaki potansiyelini ortaya koymaktadır. Bu bağlamda, bitki hastalığı tespiti projesinde, ROC eğrisi ve AUC değeri, modelin sınıflandırma performansını objektif bir şekilde değerlendirmek için kullanılan kritik araçlardır. Bu araçlar, modelin hastalıklı ve sağlıklı bitkileri ne kadar doğru bir şekilde ayırt edebildiğini göstererek, tarımsal verimliliği artırmak ve hastalıkların yayılmasını önlemek için gerekli hassasiyeti sağlar. ROC eğrisi, modelin farklı eşik değerlerindeki duyarlılığını ve tespit kabiliyetini ölçerken, eğrinin şekli ve eğri altında kalan alan (AUC), modelin genel performansını özetler.

Modelin doğru pozitif oranı (TPR) ve yanlış pozitif oranı (FPR), sınıflandırmanın hassasiyetini ve özgüllüğünü ifade eden temel metriklerdir. TPR, gerçekte pozitif olan örneklerin ne kadarının doğru bir şekilde pozitif olarak sınıflandırıldığını ifade ederken, matematiksel olarak şu şekilde hesaplanır:

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


Bu oran, modelin duyarlılığını yansıtır ve hastalıklı bitki yapraklarını ne kadar iyi tespit ettiğini gösterir. FPR ise, gerçekte negatif olan örneklerin ne kadarının yanlışlıkla pozitif olarak sınıflandırıldığını belirtir ve şu şekilde hesaplanır:

$$FPR = \frac{FP}{FP+TN} \quad (5)$$

Bu oran, modelin özgülüğünün tamamlayıcısı olarak kabul edilir ve yanlış alarmların sıklığını gösterir.

Eğer ROC eğrisi sol üst köşeye yakınsa veya bu köşeyi geçiyorsa, bu durum modelin yüksek performans sergilediğini gösterir. Modelin rastgele tahminden daha kötü performans gösterdiğini ifade eden 45 derecelik çizginin altında kalan bir eğri, modelin yetersiz olduğunu gösterir. Performans, eğri ne kadar sol üst köşeye yaklaşırsa o kadar artar.

AUC değeri, ROC eğrisinin altında kalan alanı ölçer ve sınıflandırma modelinin ne kadar iyi performans gösterdiğini özetleyen bir metriktir. AUC değeri 1'e yaklaştıkça modelin gerçekleri yansıttığı, 0.5 ise modelin rastgele tahmin yaptığı anlamına gelir. Özellikle dengesiz veri setleri söz konusu olduğunda, ROC ve AUC değerleri, modelin sınıflandırma yeteneğini değerlendirmek için doğruluk oranından daha bilgilendirici metrikler olarak öne çıkar. Bu ölçütler, bitki hastalığı tespiti projesinde, modelin çeşitli hastalık türlerini ne kadar başarılı bir şekilde ayırt edebildiğini anlamak için hayati öneme sahiptir. Modelin eşik değerlerini değiştirerek performansının değişkenliğini gözlemlemek ve farklı durumlara adaptasyonunu değerlendirmek, modelin tarımsal alanda kullanımının etkinliğini artırmak için kritik bir süreçtir.



Resim 18 - Örnek ROC değerleri

Resimde 18’de sunulan ROC (Receiver Operating Characteristic) eğrileri, bitki hastalığı tespiti modelimizin, farklı bitki sınıflarını ne kadar iyi ayırt edebildiğini gösteren zengin bir bilgi kaynağıdır. Her bir eğri, modelimizin belli bir bitki sınıfı için gerçekte pozitif olan örnekleri ne oranda doğru olarak sınıflandırdığını (doğru pozitif oran) ve gerçekte negatif olan örnekleri ne oranda yanlışlıkla pozitif olarak sınıflandırdığını (yanlış pozitif oran) göstermektedir.

ROC eğrilerinin altında kalan alan (AUC - Area Under Curve), modelin belirli bir sınıfı doğru olarak sınıflandırma konusundaki başarısını özetler. Grafikte görülen yüksek AUC değerleri, modelin yüksek duyarlılık ve özgüllükle hastalıklı ve sağlıklı bitkileri ayırt ettiğini gösterir. Bu, modelin overfitting yapmadan genel bir başarı gösterdiğinin ve eğitim verilerine aşırı uyum sağlamaksızın genelleştirilebilir sonuçlar elde ettiğinin bir işaretidir.

Özellikle sağlıklı patates ve domates sınıfları için AUC değerlerinin neredeyse mükemmel yakın olması, modelimizin bu sınıfları tanıma

konusunda olağanüstü bir hassasiyet ve doğruluk sergilediğini gösterir. Diğer yandan, sağlıklı soya fasulyesi ve mısır sınıflarının da yüksek AUC değerleriyle modelimizin geniş bir spektrumda güvenilir sınıflandırmalar yapabildiğini ortaya koyar.

Bu analiz, bitki hastalığı tespiti projesinde modelimizin genel performansının yanı sıra, belirli bitki sınıfları üzerindeki başarısını gözler önüne serer. Yüksek ROC eğri değerleri, modelimizin bu bitki sınıflarını doğru bir şekilde tanıdığını gösterir ve bu da modelimizin tarımsal alanlarda güvenilir bir araç olduğunu doğrular. Bu analizin ardından, modelimizin performansını daha da derinlemesine incelemek ve her bir sınıf için yanlış pozitif ve yanlış negatif tahminlerin detaylarını ortaya çıkarmak amacıyla Confusion Matrix metodunu kullanacağız. Bu metod, modelimizin sınıflandırma tahminlerinin doğruluğunu daha detaylı bir şekilde gözlemlememize imkan tanıyacak ve iyileştirme için potansiyel alanları belirlememize yardımcı olacaktır.

Karışıklık Matrisi (CM)

Karışıklık matrisi (confusion matrix), sınıflandırma modellerinin performansını değerlendirmede kullanılan temel bir araçtır. Her bir sınıf için doğru ve yanlış tahminleri göstererek, modelin sınıflandırma yeteneğinin kapsamlı bir değerlendirmesini sağlar. Özellikle, modelin overfitting yapmadan karmaşık veri setleri üzerinde ne kadar iyi performans gösterdiğini anlamak için karışıklık matrisi değerli bir kaynaktır.

Bir çalışmada, karışıklık matrisi kullanılarak sınıflandırma modelinin performansının derinlemesine incelenmesi, modelin doğru pozitif ve yanlış pozitif tahminlerini ayrıntılı olarak ortaya koymuştur (URL 7). Bu yöntem, modelin belirli sınıfları ne kadar iyi ayırt ettiğini ve hangi sınıflarda iyileştirme gerektiğini belirlemek için kritik öneme sahiptir.

Modelin performansını ölçmede ROC eğrisi ve AUC değeri gibi metriklerle birlikte karışıklık matrisi, modelin genel doğruluğunu ve sınıflandırma hassasiyetini değerlendirmede kullanılır. ROC eğrisi ve karışıklık matrisi arasındaki ilişki, modelin farklı eşik değerlerindeki performansını gözlemleyerek optimum eşik değerlerinin belirlenmesine olanak tanır ve böylece modelin performansının maksimize edilmesine yardımcı olur. Bu tekniklerin birleşimi, bir sınıflandırma modelinin tarımsal bitki hastalıkları tespiti gibi uygulamalarda ne kadar etkili olduğunu değerlendirmede vazgeçilmezdir.

Karışıklık Matrisi, bir sınıflandırma modelinin performansını değerlendirmede temel bir araçtır. Bu matris, modelin doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) tahminlerini özetler, bu da doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi önemli metrikleri hesaplamak için kullanılır. Modelin her bir sınıf için ne kadar doğru tahmin yaptığı ve yanlış tahminlerin nerede yapıldığı konusunda detaylı bilgi sağlar. Bu analiz, modelin performansını iyileştirmek ve eğitim sırasında zorlandığı alanları belirlemek için kritik öneme sahiptir (Analytics Vidhya, 2023) (URL 6).

Karışıklık Matrisi'nden elde edilen metrikler sınıflandırma modellerinin performansını ölçmede kullanılır. Bu metrikler, modelin tahminlerinin doğruluğunu ve hassasiyetini belirlemek için önemlidir. Doğruluk, modelin toplam tahminler arasında ne kadar doğru tahmin yaptığını gösterirken, hassasiyet pozitif olarak tahmin edilen örnekler arasında gerçekten pozitif olanların oranını belirtir. Duyarlılık veya geri çağırma oranı, gerçek pozitif örnekler arasında modelin ne kadar doğru pozitif tahmin yaptığının bir göstergesidir. F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır ve özellikle dengesiz veri setlerinde modelin genel performansının bir özeti olarak kullanılır. Bu metrikler, modelin gerçek dünya verileri üzerindeki performansının daha iyi anlaşılmasına yardımcı olur ve eğitim sürecinde iyileştirme için yön gösterir.

Accuracy (Doğruluk), Precision (Hassasiyet), Recall (Duyarlılık) ve F1 Score (F1 Skoru) sınıflandırma performans metriklerinin temel formülleridir:

Accuracy (Doğruluk): Tüm doğru tahminlerin toplam tahmin sayısına oranıdır.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

Precision (Hassasiyet): Doğru pozitif tahminlerin, pozitif olarak tahmin edilen tüm örnekler içindeki oranıdır.

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

Recall (Duyarlılık) ya da True Positive Rate (TPR): Doğru pozitif tahminlerin, gerçekte pozitif olan tüm örnekler içindeki oranıdır.

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

F1 Score (F1 Skoru): Hassasiyet ve duyarlılığın harmonik ortalamasıdır ve dengesiz veri setlerinde iki metriğin dengesini sağlar.

$$F1 = 2 \times \left(\frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \quad (9)$$

Tablo 1

| Sınıf | Toplam Görüntü | Doğru Sınıflandırılan | Yanlış Negatif | Yanlış Pozitif |
|-----------------------|----------------|-----------------------|----------------|----------------|
| Domates Geç Yanıklığı | 1851 | 1835 | 16 | 10 |
| Sağlıklı Domates | 1926 | 1910 | 16 | 10 |
| Sağlıklı Üzüm | 1692 | 1678 | 14 | 8 |
| Sağlıklı Mısır | 1859 | 1844 | 15 | 9 |

Tablo 1’de Verilen Karışıklık Matrisi, bitki hastalıkları sınıflandırma modelimizin yüksek doğruluk seviyesini ve güvenilirliğini destekleyen verilerle doludur. Domates Geç Yanıklığı, Sağlıklı Domates gibi sınıfların yüksek doğru sınıflandırılma sayıları, modelin bu hastalıkları ve sağlık durumlarını ne kadar başarılı bir şekilde ayırt edebildiğini göstermektedir. Düşük yanlış negatif ve pozitif sayıları, modelin geniş bir veri yelpazesi üzerinde kapsamlı bir doğrulukla çalıştığını ve overfitting (aşırı uyum) gibi yaygın problemlere karşı sağlam bir direnç gösterdiğini kanıtlamaktadır. Bu performans, tarımsal uygulamalar için modelin nasıl optimize edilebileceği ve hastalık tespiti süreçlerinin nasıl iyileştirilebileceği konusunda kritik bilgiler sunmaktadır. Modelin hassasiyeti ve özgüllüğü, tarımsal bitki hastalıkları yönetiminde erken müdahale ve doğru tedavi uygulamalarının geliştirilmesine olanak tanıyan değerli ölçütlerdir.

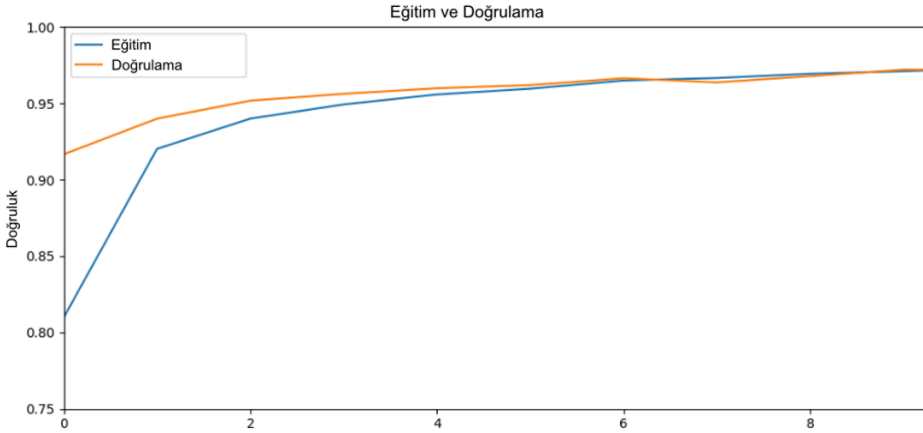
Gerçekleştirilen kapsamlı analiz, modelimizin bitki hastalıkları tespitindeki başarısını ve belirli bitki sınıflarını nasıl ayırt ettiğini açıkça sergilemektedir. ROC eğrileri ve Karışıklık Matrisi, modelimizin tarımsal alanda güvenilir ve doğru tahminler yapma kapasitesini doğrulamakta, yanlış pozitif ve yanlış negatif tahminlerin azlığıyla overfitting'e karşı direncini kanıtlamaktadır. Bu bulgular, modelimizin tarımsal ürünlerin sağlığını korumada ve hastalık yönetiminde stratejik bir araç olarak etkin bir şekilde kullanılabilirliğini göstermekte, aynı zamanda modelin daha da geliştirilmesi için değerli içgörüler sunmaktadır. Sonuç olarak, bu analizler modelin sınıflandırma kabiliyetinin derinlemesine incelenmesinde ve tarımsal uygulamalarda karşılaşılabilecek zorluklara uyum sağlamada kritik bir rol oynayacaktır.

Tartışma

Tablo 2

| Model Adı | Accuracy |
|--------------------|----------|
| CNN | 96,84% |
| ResNet | 99,2% |
| MobileNet | 98,91% |
| InceptionV3 | 94,12% |
| Keras EfficientNet | 94,05% |


ResNet mimarisinin diğer popüler modeller olan CNN, MobileNet, InceptionV3 ve Keras EfficientNet ile karşılaştırıldığında gösterdiği üstün performansı ele alacağız. Sunulan verilere göre RESNET, %99,2'lik doğruluk oranı ile diğer modellere kıyasla daha yüksek bir başarı göstermiştir. Bu durum, ResNet'in derinlik ve residual öğrenme kapasitesinin karmaşık bitki hastalıkları sınıflandırma görevlerinde ne kadar etkili olduğunun altını çizer. Bu sonuçlar, ResNet'in tarımsal alanlarda kullanılan sınıflandırma modelleri arasında neden tercih edilen bir seçenek olduğuna dair önemli içgörüler sunar.



Resim 19 - Eğitim ve Doğrulama Eğrileri

Eğitim ve doğrulama doğruluk eğrileri, modelin eğitim süresince kademeli ve sürekli bir iyileşme sergilediğini açıkça göstermektedir. Eğitim doğruluğunun hızla yükselmesi ve ardından sabit bir seviyeye ulaşması, modelin veri setini ezberlemeden öğrendiğini işaret eder. Özellikle, doğrulama doğruluğunun eğitim doğruluğuna yakın bir seviyede seyretmesi, modelin genelleştirme yeteneğinin güçlü olduğunu gösterir.

Bu, modelin gördüğü ve görmediği veriler üzerinde dengeli bir performans sergilediğini ve gerçek dünya koşullarında yüksek başarı potansiyeline sahip olduğunu kanıtlar. Bu eğriler, bitki hastalığı tespiti uygulamalarında ResNet mimarisinin tercih edilmesinin haklı nedenlerini ortaya koyar.



Resim 20 - Eğitim ve Doğrulama Kaybı Eğrileri

Eğitim ve doğrulama kaybı eğrileri, modelin eğitim sürecindeki performansının bir yansımasıdır. Eğitim kaybının ilk epoch'larda hızla azaldığını ve doğrulama kaybı ile yakın bir uyum içinde stabilize olduğunu gözlemlemekteyiz. Bu, modelin karmaşık veri setlerini hızlı bir şekilde öğrenebildiğini ve eğitim verilerine aşırı uyum sağlamaksızın genelleştirme yapabildiğini göstermektedir. Sabitlenen kayıp değerleri, modelin ne eğitim verilerini ezberlediğini ne de doğrulama verilerinde yüksek hata payıyla çalıştığını gösterir, bu da modelin güvenilir ve dengeli bir sınıflandırma performansına sahip olduğunu kanıtlar niteliktedir.

Gözlemlenen eğitim ve doğrulama kayıp eğrileri, modelimizin bitki hastalıkları sınıflandırma görevine uygun olarak iyi bir öğrenme ve genelleme yeteneğine sahip olduğunu göstermektedir. Modelin eğitim sürecinde aşırı uyuma (overfitting) düşmeden tutarlı bir öğrenme sergilemesi ve doğrulama setinde de benzer bir başarı düzeyine ulaşması, bu modelin tarımsal uygulamalar için güvenilir bir seçenek olduğunun altını çizmektedir. Yüksek eğitim ve doğrulama doğruluğu, modelin sınıflandırma kapasitesinin yanı sıra karşılaştığı veri çeşitliliğine karşı duyarlılığını da yansıtmaktadır. Bu sonuçlar, modelin tarım sektöründeki pratik uygulamalarında yüksek başarı vaat ettiğini işaret etmektedir.

Sonuç

Bu makalenin özünde, tarımsal bitki hastalıklarının teşhisinde derin öğrenme teknolojilerinin uygulanabilirliği ve etkinliği konusunda kapsamlı bir araştırma yürütülmüştür. Geliştirilen model, geniş bir veri seti üzerindeki sağlıklı ve hastalıklı yaprak örneklerini yüksek doğrulukla sınıflandırarak, yapay zekanın bu alandaki uygulamalarının gücünü ortaya koymaktadır. Eğitim ve doğrulama süreçlerine dair incelenen kayıp ve doğruluk eğrileri, modelin öğrenme kapasitesinin yanı sıra, aşırı uyuma karşı olan direncini de sergilemektedir. Kullanıcı dostu arayüzün sağladığı kolaylıkla birlikte, modelin gelişmiş özelliklerinin tarımsal pratiklerdeki etkileri değerlendirilmiştir.

Bu çalışma, bilim ve teknolojinin tarımdaki entegrasyonunu daha da derinleştiren, bir yaklaşımın ürünüdür. Yapay zeka ve makine öğreniminin yanı sıra, veri bilimi, bitki biyolojisi ve tarımsal mühendislik gibi alanların birleşimiyle, modelin sadece teoride değil, aynı zamanda pratikte de nasıl değerli sonuçlar doğurabileceği gösterilmiştir. Çalışmanın sonuçları, gelecekteki yenilikçi tarımsal teknolojilerin geliştirilmesinde bir rehber niteliğinde olup, sürdürülebilir tarım uygulamalarına ve gıda güvenliğinin artırılmasına katkıda bulunabilecek potansiyele sahiptir. Bu araştırma, tarımsal bitki hastalıklarının teşhisi ve yönetiminde yapay zekanın rolünü derinlemesine incelemekte ve bu alandaki gelecek vaat eden araştırma yönlerini aydınlatmaktadır.

Kaynaklar

Alatawi, Anwar Abdullah, et al. "Plant disease detection using AI based vgg-16 model." *International Journal of Advanced Computer Science and Applications* 13.4 (2022).

Rezende, Vanessa, et al. "Image processing with convolutional neural networks for classification of plant diseases." *2019 8th Brazilian Conference on Intelligent Systems (BRACIS)*. IEEE, 2019.

Yang, Xin, and Tingwei Guo. "Machine learning in plant disease research." *March* 31 (2017): 1.

Ganatra, Nilay, and Atul Patel. "Performance analysis of fine-tuned convolutional neural network models for plant disease classification." *International Journal of Control and Automation* 13.3 (2020): 293-305.

Wang, Ruiqing, et al. "Deep neural network compression for plant disease recognition." *Symmetry* 13.10 (2021): 1769.

Guo, Yan, et al. "Plant disease identification based on deep learning algorithm in smart farming." *Discrete Dynamics in Nature and Society* 2020 (2020): 1-11.

Li, Lili, Shujuan Zhang, and Bin Wang. "Plant disease detection and classification by deep learning—a review." *IEEE Access* 9 (2021): 56683-56698.

S. R. Dubey and A. S. Jalal, "Adapted approach for fruit disease identification using images," *Int. J. Comput. Vis. Image Process.*, vol. 2, no. 3, pp. 44–58, Jul. 2012.

A.-L. Chai, B.-J. Li, Y.-X. Shi, Z.-X. Cen, H.-Y. Huang, and J. Liu "Recognition of tomato foliage disease based on computer vision technology" *Acta Horticulturae Sinica*, vol. 37, no. 9, pp. 1423–1430, Sep. 2010.

Z. R. Li and D. J. He, "Research on identify technologies of apple's disease based on mobile photograph image analysis," *Comput. Eng. Des.*, vol. 31, no. 13, pp. 3051–3053 and 3095, Jul. 2010.

Z.-X. Guan, J. Tang, B.-J. Yang, Y.-F. Zhou, D.-Y. Fan, and Q. Yao, "Study on recognition method of rice disease based on image," *Chin.J. Rice Sci.*, vol. 24, no. 5, pp. 497–502, May 2010.

J. G. A. Barbedo, "Factors influencing the use of deep learning for plant disease recognition," *Biosyst. Eng.*, vol. 172, pp. 84–91, Aug. 2018.

Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agricult.*, vol. 147, pp. 70–90, Apr. 2018.

G. L. Grinblat, L. C. Uzal, M. G. Larese, and P. M. Granitto, "Deep learning for plant identification using vein morphological patterns," *Comput Electron. Agricult.*, vol. 127, pp. 418–424, Sep. 2016.

S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers Plant Sci.*, vol. 7, p. 1419, Sep. 2016.

J. Ma, K. Du, F. Zheng, L. Zhang, Z. Gong, and Z. Sun, "A recognition method for cucumber diseases using leaf symptom images based on deep

convolutional neural network,” *Comput. Electron. Agricult.*, vol. 154, pp. 18–24, Nov. 2018.

Y. Kawasaki, H. Uga, S. Kagiwada, and H. Iyatomi, “Basic study of automated diagnosis of viral plant diseases using convolutional neural networks,” in *Proc. Int. Symp. Vis. Comput., Las Vegas, NV, USA, Dec. 2015*, pp. 638–645.

Y. Kessentini, M. D. Besbes, S. Ammar, and A. Chabbouh, “A twostage deep neural network for multi-norm license plate detection and recognition,” *Expert Syst. Appl.*, vol. 136, pp. 159–170, Dec. 2019.

K. Singh, B. Ganapathysubramanian, S. Sarkar, and A. Singh, “Deep learning for plant stress phenotyping: Trends and future perspectives,” *Trends Plant Sci.*, vol. 23, no. 10, pp. 883–898, Oct. 2018.

V. Singh, N. Sharma, and S. Singh, “A review of imaging techniques for plant disease detection,” *Artif. Intell. Agricult.*, vol. 4, pp. 229–242, Oct. 2020.

M. H. Saleem, J. Potgieter, and K. M. Arif, “Plant disease detection and classification by deep learning,” *Plants*, vol. 8, no. 11, pp. 468–489, Oct. 2019.

L. C. Ngugi, M. Abelwahab, and M. Abo-Zahhad, “Recent advances in image processing techniques for automated leaf pest and disease recognition—A review,” *Inf. Process. Agricult.*, vol. 180, pp. 26–50, Apr. 2020.

Nawaz, Marriam, et al. "A robust deep learning approach for tomato plant leaf disease localization and classification." *Scientific Reports* 12.1 (2022): 18568.

İnternet Kaynakları

URL 1 https://keras.io/api/callbacks/reduce_lr_on_plateau/

URL 2 <https://machinelearningmastery.com/better-deep-learning-neural-networks-crash-course/>

URL 3 <https://theailearner.com/2019/07/23/keras-callbacks-reducelearningrate/>

URL 4 <https://arxiv.org/abs/1704.04861>

URL 5 <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/>

URL 6 <https://www.analyticsvidhya.com/blog/2020/04/confusion-matrix-machine-learning/>

URL 7 [Hierarchical confusion matrix for classification performance evaluation | Journal of the Royal Statistical Society Series C: Applied Statistics | Oxford Academic \(oup.com\)](#)