

Seboreik & Atopik Dermatit, Psoriasis, Onikomikoz Hastalıklarının Yapay Zekâ ile Tespit Edilmesi

Kevser ŞAHİNBAŞ^{1*}, Berna Şevval UYSAL², Zeliha SEZGİN³, Sude TOZMAZ⁴

Öz

Bu çalışma, seboreik dermatit, atopik dermatit, psoriasis ve onikomikoz hastalıklarının yapay zekâ teknolojisi kullanılarak doğru ve hızlı bir şekilde tespit edilmesini hedeflemektedir. Yapay zekâ teknolojilerinin bu alanda kullanımı, teşhis süreçlerini hızlandırarak ve doğruluk oranını artırarak önemli avantajlar sunmaktadır. Bu çalışma kapsamında, yapay zekânın önemli bir dalı olan derin öğrenme teknikleri kullanılmıştır. YOLO algoritması kullanılarak, cilt hastalıklarının görüntüler üzerinden yüksek doğrulukla teşhis edilmesi amaçlanmıştır. Önerilen modelin geliştirilmesi için Kaggle'dan elde edilen veri seti kullanılmış ve model eğitilmiştir. Veri seti, seboreik dermatit, atopik dermatit, psoriasis ve onikomikoz hastalıklarına ait yüksek çözünürlüklü cilt görüntülerini içermektedir. Çalışmanın metodoloji kısmında, verilerin ön işleme tabi tutulması, modelin geliştirilmesi ve test edilmesi aşamaları ayrıntılı bir şekilde ele alınmıştır. Veriler makine öğrenimine sunulmadan önce RoboFlow üzerinden tek sınıflı sınıflandırma işlemleri yapılmış ve görüntüler 640x640 standart boyutlarına getirilmiştir. Model için, Yolov8 algoritmasının yolov8s-cls modeli kullanılmış ve Google Colab ortamında kodlanmıştır. Modelin eğitimi sırasında, eğitim, doğrulama ve test veri setleri kullanılarak modelin performansı değerlendirilmiştir. Model, %88.3 doğruluk oranına ulaşmış ve hastalıkları başarılı bir şekilde sınıflandırmıştır. Elde edilen doğruluk oranları, bu tür modellerin klinik uygulamalarda kullanıma potansiyelini ortaya koymaktadır. Bu çalışma, sağlık sektöründe yapay zekâ tabanlı sistemlerin kullanımının yaygınlaşmasına ve teşhis süreçlerinin iyileştirilmesine katkıda bulunmayı amaçlamaktadır.

Anahtar Kelimeler: Cilt Hastalıkları, Yapay Zekâ, RoboFlow, YOLOv8, Sınıflandırma, Evrişimsel Sinir Ağları.

Detection of Seborrheic & Atopic Dermatitis, Psoriasis, Onychomycosis Diseases with Artificial Intelligence

Abstract

This study aims to accurately and rapidly detect seborrheic dermatitis, atopic dermatitis, psoriasis and onychomycosis diseases using artificial intelligence technology. The use of artificial intelligence technologies in this field offers significant advantages by accelerating diagnosis processes and increasing the accuracy rate. Deep learning techniques, an important branch of artificial intelligence, were used in this study. It is aimed to diagnose skin diseases with high accuracy from images using the YOLO algorithm. The dataset obtained from Kaggle was used to develop the proposed model and the model was trained. The dataset contains high-resolution skin images of seborrheic dermatitis, atopic dermatitis, psoriasis and onychomycosis diseases. In the methodology section of the study, the stages of pre-processing the data, developing the model and testing the model are discussed in detail. Before the data was submitted to machine learning, single-class classification operations were performed via RoboFlow and the images were brought to the standard size of 640x640. For the model, the yolov8s-cls model of the Yolov8 algorithm was used and coded in the Google Colab environment. During the training of the model, the performance of the model was evaluated using training, validation and test data sets. The model reached an accuracy rate of 88.3% and successfully classified the diseases. The accuracy rates obtained reveal the potential of such models to be used in clinical applications. This study aims to contribute to the widespread use of artificial intelligence-based systems in the healthcare sector and to the improvement of diagnostic processes.

Keywords: Skin Diseases, Artificial Intelligence, RoboFlow, YOLOv8, Classification, Convolutional Neural Networks.

¹İstanbul Beykent Üniversitesi, Fen Edebiyat Fakültesi, Bilişim Sistemleri ve Teknolojileri Bölümü, İstanbul, Türkiye, kevsers@beykent.edu.tr

^{2,3,4}İstanbul Medipol Üniversitesi, Yönetim Bilişim Sistemleri, İstanbul, Türkiye,
bernausyal019@gmail.com sezginzeliha03.19@gmail.com sudeetozmazz1390@gmail.com

*Sorumlu Yazar/Corresponding Author

1. Giriş

Cilt hastalıklarının doğru ve hızlı bir şekilde teşhis edilmesi, etkili bir tedavi için önemli bir rol oynamaktadır. Bunun yanında geleneksel teşhis yöntemleri zaman alıcı olmaktadır ve bazen hata payı içerebilmektedir. Yapay zekâ teknolojilerinin bu hastalıkların tespiti üzerindeki etkisi, araştırma problemimizin temelini oluşturmaktadır.

Yapay zekâ, insan zekâsına ait olarak kabul edilen kabiliyetleri taklit edebilen bilgisayarlar veya bilgisayar destekli sistemler şeklinde tanımlanmaktadır ve karmaşık problemleri çözme, öğrenme, deneyimlerden ders çıkarma ve karar verme gibi süreçleri gerçekleştirebilmektedir. Yapay zekânın sahip olduğu bu kapasitesi, teknolojik yeniliklerle, özellikle insansı robotlar ve akıllı otomasyon sistemlerinde, değerli ilerlemeler kaydetmektedir. Biyolojik sinir ağlarının yapısından esinlenerek geliştirilen yapay sinir ağları, yapay zekânın öğrenme ve doğru bilgiyi uygulama yeteneklerinin temelini oluşturmaktadır (Öztürk & Şahin, 2018).

Deri hastalıkları günümüzde her yaş grubunda olan insanı etkileyecek şekilde çok yaygın biçimde görülmektedir. Vücudun en büyük immünolojik organlarından biri olan deri, vücudu dış tehlikelere karşı korumaktadır. Atopik dermatit, seboreik dermatit, sedef hastalığı gibi birçok cilt hastalığına, doğuştan gelen ve kazanılmış bağışıklıktaki anormalliklerle birlikte bağışıklık sistemi aracılık etmektedir. Bu hastalıkların çoğu hem genetik hem de çevresel faktörlerin önemli rol oynadığı kronik, inflamatuvar ve proliferatif hastalıklardır (Fonacier ve ark., 2010).

Cilt, vücudu dış etkenlere karşı koruyan, duyarımızın bir kısmını sağlayan ve birçok önemli fonksiyona sahip olan en büyük organdır. Cilt hastalıkları, deri üzerinde meydana gelen çeşitli anomali ve bozuklukları ifade eden genel bir terimdir. Cilt hastalıkları, deri üzerinde görülen değişiklikler, lezyonlar, kaşıntı, kızarıklık ve diğer belirtilerle tespit edilebilmektedir. Bu hastalıklar, genetik faktörler, çevresel etkenler, enfeksiyonlar, alerjiler ve bağışıklık sistemi reaksiyonları gibi çeşitli nedenlerle ortaya çıkabilmektedir.

Hassas cilt, iç ve dış uyaranlara karşı aşırı duyarlı olan bir cilt durumudur. Bu durum zamanla can sıkıcı bir hal almaktadır ve insanlar cildinde ortaya çıkan hastalığın ne olduğunu hemen anlayamamaktadır. Bunun sonucunda insanlar internet üzerinden ne sorunun olduğunu araştırarak yanlış bilgiler edinmektedir ve kendi kendine yanlış tanımlar koymaktadırlar. Bu durumda evde yanlış tedavi yüzünden cilt hastalığını ileri boyuta taşımaktadır.

Dermatolojik hastalıklar gelişmiş ve gelişmekte olan ülkelerde önemli bir sağlık sorunu oluşturmaktadır. Dünya çapında ölümcül olmayan hastalık yükü arasında dördüncü sırada yer almaktadır (Rasheed ve ark., 2022). Çevresel faktörler, bronzlaşma, ultraviyole radyasyon alkol vb. gibi birçok faktör cilt hastalıklarına katkıda bulunmaktadır. Cilt hastalıkları insanların sağlığı, refahı ve yaşam kalitesi için yıkıcı bir tehdit oluşturmaktadır. Bunlar etkileşim ve ilişkilerde zorluklara,

duygusal sıkıntıya, kaygıya, fiziksel olarak görüntü bozukluğuna, yalnızlığa ve işsizliğe sebep olabilmektedir. Picardi ve arkadaşları (2013) yaptıkları çalışmada, cilt sorunları olan hastalarda ölüm arzusunun ve intihar düşüncesinin yüksek oranlarda meyilli olduğunu ortaya koymuşlardır (Picardi ve ark., 2013).

Dermatit veya egzama, cildin tahriş olmasına, iltihaplanmasına veya kaşınmasına neden olan bir grup cilt rahatsızlığıdır (Rasheed, ve diğerleri, 2022). Yüzeysel mantar enfeksiyonları deri, saç ve tırnaklar gibi keratinize dokuların dermatofit enfeksiyonlarıdır (Koo ve ark., 2021). Sedef hastalığı kalıcı, bulaşıcı olmayan ve iltihaplı bir hastalıktır. Sedef hastalığı olan hastalar, hastalığa genetik bir yatkınlığa sahiptir. Lezyonlar tipik olarak kafa derisi, gövde, dirsekler ve dizlerde görülür (Lyons & Ousley, 2014).

Bu araştırma ile amaçlanan belirtilen deri hastalıklarının tespit edilerek yüksek oranda doğru bir tanı koyarak insanları doktora gitmeden önce bilgilendirmektir. Kısacası insanların cilt hastalıklarının belirlenmesinde herhangi bir paniğe kapılmadan yapılacak olan uygulama ile uygun bir şekilde tahmin edilmesi hedeflenmektedir. Yapılacak olan araştırmalar, cilt hastalıklarının yapay zekâ ile tespiti konusundaki literatürdeki boşluğu doldurarak, sağlık sektöründe yenilikçi bir yaklaşım sunmayı amaçlamaktadır. Yapay zekânın kullanımıyla elde edilen hızlı ve yüksek oranda doğru teşhisler, hastaların daha etkili bir şekilde tedavi edilmesine ve sağlık hizmetlerine daha erken ulaşmalarına olanak tanımaktadır.

Tüm insanların rahatlıkla erişip kullanabileceği bir uygulama oluşturmak ve böylelikle yaygın kullanıma ulaşmak hedeflenmektedir. Ayrıca bu projenin yayılımı ile artan deri hastalıklarının tanısının geç kalınmadan hızlı bir şekilde tahmin edilmesi hedeflenmektedir.

1.1. Benzer Çalışmalar

Bilgin ve Çifci (2021) yaptıkları çalışmada makine öğrenmesi algoritmalarının, deri hastalıklarının sınıflandırılmasında ve tahmininde ne kadar etkili olup olmadığının araştırmasını yapmışlardır. Yapılan çalışmada 366 hastaya ait 33 nitelikten oluşan deri örnekleri alınmıştır. Dermatoloji veri seti altı türden 366 örnek içeren eritematöz skuamöz hastalıklarla ilgilidir ve dağılımı şu şekildedir: Sedef hastalığı (112 hasta), seboreik dermatit (61 hasta), liken planus (72 hasta), pityriasis rosea (49 hasta), kronik dermatit (52 hasta) ve pityriasis rubra pilaris (20 hasta). Ayrıca çalışmada kullanılan algoritmalar ise; Destek Vektör Makineleri (SVM), Topluluk Öğrenme Algoritmaları (ELM), Karar Ağaçları (DT), k-En Yakın Komşuluk (k-NN) şeklindedir. Çalışma sonucunda SVM ile veri setinde %99.73' lük bir doğruluk elde edilmiştir (Bilgin & Çifci, 2021).

Çifci ve arkadaşları (2014) yaptıkları çalışmada 140 hastaya ait 33 nitelikten oluşan deri doku örnekleri Yapay Sinir Ağları geri yayımlı öğrenme algoritması yardımıyla sınıflandırmışlardır.

Problemin çözümü için MATLAB Neural Network Toolbox kullanılarak hastaların sınıflandırma başarısını irdelemiştirler. Yapılan çalışma sonucunda sedef ve liken planus deri hastalıklarının teşhisinde yardımcı olacak bir yöntem gerçekleştirilmiştir. Her iki hastalıktan 40'ar olmak üzere toplam 80 hasta eğitim ve her iki hastalıktan 30'ar olmak üzere toplam 60 hasta ise test verisi olarak belirlenmiştir. Gerçek verilerle elde edilen veriler arasındaki korelasyon katsayısı (0.98) %98'dir. Yapay Sinir Ağları modelinin üretmiş olduğu sonuçların gerçeğe en kuvvetli biçimde yakınsadığı gösterilmiştir (Çifci, İlkuçar, Bozkurt, & Uyaroğlu, 2014).

Codella ve arkadaşları (2015) bu çalışmalarında, derin öğrenmeyi, seyrek kodlamayı ve destek vektör makinesi öğrenme algoritmalarını birleştiren dermoskopi görüntülerinde melanom tanımaya yönelik bir yaklaşım sunmaktadır. Uygulanan özellik aktarımı aynı zamanda sistemin dermoskopi görüntülerdeki gözlemler ile doğal dünyadaki gözlemler arasında benzerlikler kurmasına da olanak tanıyarak, klinik uzmanlarının cilt lezyonlarındaki modelleri tanımlamak için kullandıkları süreci taklit etmektedir. Metodolojiyi değerlendirmek için performans, Uluslararası Cilt Görüntüleme İşbirliği'nden elde edilen ve 2624 klinik melanom (334), atipik nevüs (144) ve iyi huylu lezyonlar (2146) içeren bir veri seti üzerinde ölçülmüştür. Yaklaşım, bu veri kümesindeki önceki en gelişmiş yöntemle karşılaştırılmıştır. Değerlendirme için 20 kez iki katlı çapraz doğrulama gerçekleştirilmiş olup (toplam 40 deney) ve iki ayırım görevi incelenmiştir; melanom ve melanom dışı tüm lezyonlar ve melanom ve yalnızca atipik lezyonlar. Sunulan yaklaşım, ilk görev için %93,1 ve ikinci görev için %73,9 doğruluk elde edilmiştir. Yapılan çalışma sonucunda derin öğrenme yöntemleri ile klasik makine öğrenmesi yöntemleriyle özellik çıkarımı yapılarak sınıflandırma gerçekleştirilmiş ve %93 doğruluğa ulaşılabilmektedir (Codella, ve diğerleri, 2015).

Harangi (2018) çalışmasında, cilt kanseri teşhisinde derin öğrenme tabanlı yöntemlerin sınıflandırma görevlerinde geleneksel görüntü işleme metotlarına kıyasla daha etkili olduğunu gözlemlemiştir. Ancak bu yöntemlerin her sınıf için binlerce etiketli görüntü gerektirdiğini de belirtmiştir. Bu zorlukla başa çıkmak için, yeterli sayıda etiketlenmiş görüntü olmaksızın dermoskopi görüntülerini sınıflandırmada bireysel doğrulukları artırmak amacıyla derin konvolüsyonel sinir ağlarının bir topluluk öğrenmesi (Ensemble Learning) oluşturmayı önermiştir. Yöntem, dört farklı CNN mimarisini birleştirerek ve çeşitli füzyon teknikleri kullanarak 0.891 gibi yüksek bir ROC alanı elde etmiştir. Bu bulgular, cilt lezyonlarının otomatik sınıflandırılmasında topluluk öğrenmesi yaklaşımlarının etkinliğini göstermektedir ve bu alanda yapılan çalışmalara önemli bir katkı sağlamaktadır (Harangi, 2018).

Koo ve arkadaşları (2021) yaptıkları çalışmada, bir nesne tespit evrişimli sinir ağı (CNN) kullanarak 40x ve 100x büyütme mikroskopik görüntülerden yüzeysel mantar enfeksiyonlarının (yani hiflerin) otomatik tespitini sunmuşlardır. Modeli eğitmek ve test etmek için 18 pozitif vaka ve 20 negatif vaka olmak üzere toplam 38 örnek kullanmışlardır. YOLO v4 nesne algılama CNN 12,

hiflerin nesne algılamasını gerçekleştirmek üzere eğitilmişlerdir. Olasılıklar ve bir eşik kullanılarak, görüntünün pozitif (hif içeren) veya negatif (hif içermeyen) olarak sınıflandırılması için otomatik bir karar verilmesini sağlamışlardır. Bu çalışma sonucunda, mikroskopik görüntülerdeki hifleri yüksek doğrulukla tespit edebilmişlerdir.

Rahman ve arkadaşları (2023) yaptığı çalışmada derin evrişimli sinir ağlarını (CNN) kullanarak mikroskopik görüntülerden patojen mantarların sınıflandırılmasını sunmaktadırlar. DenseNet, Inception ResNet, InceptionV3, Xception, ResNet50, VGG16 ve VGG19 gibi tanınmış CNN mimarilerini mantar türlerini tanımlamak için eğitmişler ve performanslarını karşılaştırmışlardır. 89 mantar cinsine ait 1079 görüntü toplamışlar ve verilerini 7:1:2 oranına göre eğitim, doğrulama ve test veri kümelerine ayırmışlardır. DenseNet CNN modeli, 89 cinsin sınıflandırılmasında ilk 1 tahminde %65,35 genel doğruluk ve ilk 3 tahminde %75,19 doğrulukla diğer CNN mimarileri arasında en iyi performansı sağlamışlardır. Düşük örnek oluşumuna sahip nadir türler hariç tutulduktan ve veri artırma teknikleri uygulandıktan sonra performans daha da geliştirilmiştir (>%80). Bazı özel mantar türleri için %100 tahmin doğruluğu elde etmişlerdir. Yapılan çalışma sonucunda, kültürden ipliksi mantarların tanımlanmasında umut verici sonuçlar veren, teşhis doğruluğunu artırmak ve tanımlamaya yönelik geri dönüş süresini azaltmak için kullanılabilecek bir derin öğrenme yaklaşımı sunmuşlardır.

1.2. Seboreik Dermatit, Atopik Dermatit, Onikomikoz, Psoriasis Tanımları

1.2.1. Seboreik Dermatit

Seboreik dermatit, genellikle kafa derisi, yüz, kaş çizgisi, burun kanadı, göğüs ve sırt gibi yağ bezlerinin yoğun olduğu bölgelerde ortaya çıkan bir cilt durumudur. Seboreik dermatit, "seboreik bölgelere", yani yüksek yoğunlukta yağ bezlerine (yüz, göğüs kemiği, interskapüler bölge) sahip bölgelere karakteristik bir kısıtlama getiren, dermatit/egzama spektrumunun inflamatuvar bir deri hastalığıdır (Dorynska & Spiewak, 2012). Bu durum, yağ bezlerinin aşırı üretimi ve bir tür mantar olan *Malassezia*'nın cilt üzerinde artışı ile ilişkilidir. Genellikle yağlı, sarımsı veya beyaz pulların görünmesi, kaşıntı, kızarıklık ve cildin hassaslaşması gibi belirtilere neden olabilmektedir (Hay, 2011). Türkiye'de hastane kayıtlarındaki pediatrik hastalarla (0-16 yaş arası) yapılan bir çalışmada, çocukların %4,3'üne seboreik dermatit tanısı konmuştur (Tamer ve ark., 2008).

1.2.2. Atopik Dermatit

Egzama; kızarıklık, şişme, pullanma, içi su dolu kabarcıklar ve kuruluk oluşmasına neden olabilen bir cilt rahatsızlığıdır. Bu durum, genellikle ciltte kızarıklık, şişlik, kuruluk, kaşıntı ve kuru, çatlamış alanlarla kendini göstermektedir. Egzamanın en yaygın şekli, bazen atopik egzama olarak da adlandırılan atopik dermatit şeklindedir. Çoğu hasta ve doktorun egzama terimini kullanırken kastettiği egzama türü atopik dermatit'tir (Chovatiya, 2023). Atopik dermatit, kronik inflamatuvar bir cilt rahatsızlığıdır. Dünya çapında 200 milyondan fazla insanı etkilediği ve bunların arasında %20'sinin çocuk olduğu, %10'ının yetişkin olduğu Chovatiya'nın yaptığı çalışmada belirtilmektedir (Chovatiya, 2023). Atopik dermatit çocuklarda daha yaygın olmasına (ve çoğunlukla yetişkinlikte de devam etmesine) rağmen, atopik dermatiti olan yaklaşık 4 yetiştikten 1'inde yetişkin başlangıçlı hastalık vardır. Atopik dermatit gelişiminde rol oynayan faktörler arasında cilt bariyerinin zayıflaması, ciltteki bağışıklık hücrelerinin artan aktivitesi ve ciltte yaşayan mikroorganizma topluluğu (mikrobiyom) yer alır.

Atopik dermatit sıklıkla vücudun deri kıvrımları, baş, yüz ve boyun, eller ve bilekler, ayaklar ve ayak bilekleri gibi belirli bölgelerini etkiler. Kaşıntı, atopik dermatitle ilişkili en yaygın semptomdur ancak hastalar aynı zamanda cilt ağrısı ve uyku güçlüğü de yaşayabilir. Bu durum yaşam kalitesini düşürebilmektedir. Alevlenmeleri tetikleyen faktörler bireyler arasında farklılık gösterir ve fiziksel veya duygusal stres, sıcaklık veya nem değişiklikleri, terleme, alerjenler ve tahriş edici maddeleri içerebilir (Hay, 2011).

1.2.3. Onikomikoz

Mantar hastalıkları, genellikle derinin nemli ve sıcak bölgelerinde ortaya çıkan mikroorganizmaların neden olduğu enfeksiyonlardır. Dünya çapında mantar hastalığının görülme sıklığı %25'in üzerinde olan ve görülme sıklığı sürekli artan cilt hastalıkları arasında en sık görülenler arasında yer almaktadır (Havlickova ve ark., 2008). Mantarların neden olduğu hastalıklar insan vücudunun cilt, tırnak, ağız, saç gibi farklı bölgelerinde ortaya çıkar (Rahman ve ark., 2023).

Onikomikoz, tırnak mantarı olarak da bilinen bir tırnak enfeksiyonudur. Genellikle tırnak plağını ve çevresindeki dokuları etkileyen bir mantar tarafından oluşturulan bir enfeksiyondur. Bu durum genellikle tırnakların renginde, şeklinde ve kalitesinde değişikliklere neden olabilmektedir. Tırnaklarda sararma, kalınlaşma, çatlamalar, pul pul dökülme ve tırnak plakasının şekil değiştirmesi gibi belirtilerle kendini göstermektedir. Bu enfeksiyon genellikle ayak tırnaklarını etkiler, ancak el tırnaklarını da etkileyebilir. Onikomikoz, spor salonları, yüzme havuzları, ortak duş alanları gibi nemli ve sıcak ortamlarda daha sık görülebilmektedir (Gül & Çiftçi, 2022).

1.2.4. Psoriasis

Psoriasis, sedef hastalığı olarak geçmektedir. Cildin hızlı hücre üretimine ve birikimine neden olan bir otoimmün hastalıktır. Bu durum, kalın, gümüşü renkli pulların deri yüzeyinde birikmesine yol açabilmektedir. Bağışıklık sistemi hatalı bir şekilde hızlı hücre üretimi yaparak deri yüzeyinde anormal bir birikime neden olduğunda ortaya çıkmaktadır. Sedef hastalığı kalıcı, bulaşıcı olmayan ve iltihaplı bir hastalıktır. Lezyonlar tipik olarak kafa derisi, gövde, dirsekler ve dizlerde görülmektedir (Lyons & Ousley, 2014). Bu lezyonlar genellikle kaşıntılı ve bazen acılı olabilmektedir.

Psoriasis genetik yatkınlık, bağışıklık sistemi bozuklukları ve çevresel faktörlerin etkileşimi sonucunda ortaya çıkabilmektedir. Bu durum genellikle genç yetişkinlerde başlar, ancak her yaşta görülebilmektedir. Hastalığın derecesi hayat kalitesini önemli ölçüde etkilemektedir. (Kurd & Gelfand, 2009) tarafından yapılan çalışmada hafif sedef hastalığı olan hastaların %16'sı bunu büyük bir sorun olarak değerlendirirken, orta ila şiddetli sedef hastalığı hastalarının %72'si bunu büyük bir sorun olarak değerlendirilmiştir.

Psoriasis'in farklı türleri bulunmaktadır, ancak en yaygın olanları plak psoriasisidir. Bu tür, vücudun farklı bölgelerinde yaygın olarak görülen kırmızımsı plaklar ve pullarla karakterizedir. Diğer türler arasında guttate psoriasis (damla şeklinde küçük lekeler), invers psoriasis (koltuk altı, kasık gibi kıvrımlı bölgelerde görülen lezyonlar) ve pustüler psoriasis (cerahat dolu kabarcıklar) bulunmaktadır.

1.3. Yapay Zekâ

Teknolojinin ilerlemesiyle günümüzde genel olarak etkin şekilde kullanılan Yapay Zekâ insanların hayatını kolaylaştırmayı amaçlayan bir teknolojidir. Hemen hemen her alanda kullanılan yapay zekâ teknolojisi, doğru veriler ve doğru analizlerle sağlık alanında da çok değerli sonuçlar vermektedir. Özellikle, görüntü işleme teknolojisi kullanılarak cilt hastalıklarının tespiti konusunda yapay zekâ modelleri çok yönlü ve doğru sonuçlar verebilir. Bu sayede, cilt hastalıklarını tespit etme süreçleri hızlanabilir ve doğruluk oranlarını artırabilir. Bu çalışmada, yapay zekâ sistemi, görüntüleri tarayarak egzama, mantar ve sedef hastalıklarını büyük oranda doğrulukla teşhis etme ve bu bilgi hastaların, doktora muayene olmadan önce hastalığını tespit edebilmesi ve bilgi alması için kullanılmasına yardımcı olmayı amaçlamaktadır.

1.3.1.Derin Öğrenme

Derin öğrenme, yapay zekâ ve makine öğrenmesinin önemli bir dalıdır ve çok katmanlı yapay sinir ağları kullanarak büyük miktarda veriyi işleme kapasitesine sahiptir. Derin öğrenme modelleri, büyük veri kümelerindeki karmaşık kalıpları tanımlamak ve öğrenmek için tasarlanmıştır. Bu modeller, görüntü tanıma, doğal dil işleme, konuşma tanıma ve diğer birçok alanda etkileyici sonuçlar elde etmiştir.

Derin öğrenme, derin bir sinir ağı kullanarak verilerden otomatik olarak özellik çıkartarak öğrenim sürecini geliştirmektedir. Buradaki esas nokta modeli yeterli miktarda veri ile beslemektir. Derin öğrenme tekniklerinin makine öğrenmesi tekniğinden farkı, daha fazla deneyim ile daha fazla veri üzerinde çalışarak yüksek bir verimlilik ile performans göstermesidir. Sınıflandırma görevlerinde “uçtan uca öğrenme” gerçekleştirerek bağımsız ve otomatik bir şekilde öğrenmektedir (Eker & Duru, 2021).

1.3.2.Sağlık Alanında Yapay Zekâ

Yapay zekâ, sağlık sektöründe küresel büyüklükte yoğun ilgi görmektedir ve sağlık hizmetleri yönetimi, tahmini tıp, hasta verilerinin analizi ve klinik karar verme aşamalarında ciddi bir rol oynamaktadır. Özellikle Amerika Birleşik Devletleri, Çin ve Birleşik Krallık gibi ülkeler, yapay zekâ kullanımında diğer ülkelere öncülük ederek, doktorların teşhis koymalarını, hastalıkların yayılmasını tahmin etmelerini ve tedavi yöntemlerini hastalara göre oluşturmalarını desteklemektedir (Çilhoroz & Işık, 2021). Yapay zekâ, maliyetleri en düşük seviyeye indirme ve tedavi aşamalarında doğruluk sağlama gibi avantajlar sunmaktadır. Sağlık hizmetlerinde yapay zekâ ilerledikçe, finansal sürdürülebilirlik ve hastalara verilen hizmet kalitesinin iyileştirme potansiyeline de artmaktadır.

Ek olarak, bu bağlamda yapay zekâ kullanımı, artan kronik hastalık yükü, yaşlanan nüfus ve sağlık hizmetlerine yönelik zamanla beraber değişen beklentilerle daha da önem kazanmaktadır. Yapay zekâ teknolojisi, sağlık hizmetlerinde teşhis, tedavi ve yönetim aşamalarını hızlandırarak maliyetleri en düşük seviyeye indirebilir ve hizmet kalitesini artırma potansiyeline sahiptir. Sağlık sektöründeki yapay zekâ uygulamalarının aktifliğini ve kapsamını daha iyi anlayabilmek için gelecekteki araştırmalar, bahsedilen teknolojinin sağlık hizmetlerinde stratejik bir değişim aracı olarak nasıl kullanılabileceğini değerlendirmektedir. Bu bakış açıları bir araya geldiğinde, yapay zekâ'nın sağlık çalışanlarının performansını artırma ve hasta bakımını iyileştirme potansiyelini vurgulayan çalışmalar da bulunmaktadır; bu çalışmalar, sağlık hizmetlerinde yapay zekâ'nın farklı uygulamalarını ve araştırma alanındaki boşlukları göstermektedir (Hazarika, 2020). Bu bağlamda yapay zekâ teknolojisinin genişletilmesi verilen hizmetlerin kalitesini artırma potansiyeline sahiptir.

1.3.3. Sağlık Alanında Yapay Zekâ Uygulamaları

2021 yılında Google tarafından geliştirilen ancak henüz kullanıma sunulmayan Derm Assist Uygulaması, kullanıcılardan belirli bir bölgenin fotoğrafını çekmesini ister ve cilt, saç, tırnak hastalıklarının tahmini yapmaya yarar. Bu proje henüz kullanıma açılmadığından hastalık tespiti için kesin bir doğruluk payı verilememektedir. Bu araştırma bağlamında geliştirilen proje Derm Assist'ten farklı olarak kullanıcıların yalnızca mantar, egzama ve sedef hastalıklarını tahmin etmeye odaklandığından daha kapsamlı veri setiyle daha yüksek oranda doğru sonuç vermesini amaçlamaktadır.

2021 yılında T.C. Sağlık Bakanlığı tarafından geliştirilen "Neyim Var?" Projesi, kullanıcılardan hastalıklarının tarif edilmesi için bazı seçeneklerin işaretlenmesiyle bir hastalık tahmini yapmaya yarar. "Neyim Var?" Projesi'nde görsel veriler kullanılmamakta olup, hastaların yanlış semptomları girmesine sebebiyet vermektedir. Bu araştırma bağlamında geliştirilen proje, bu uygulamadan farklı olarak vücudun ilgili bölgesinin fotoğraf verileriyle kişilerin hastalık tahminini kolaylaştırmasını ve yanlış semptom girişinin azaltılmasını amaçlamaktadır.

Bu araştırma kapsamında geliştirilen projenin, tüm güncel çalışmalardan farklı olan yönü kullanıcının herhangi bir yazılı bilgi girmesine gerek kalmadan yalnızca fotoğraf çekmesiyle yapay zekâ tarafından tespiti yapıp hastaların bir ön bilgiye sahip olmasını sağlamaktır.


2. Materyal ve Metot

Evrişimli Sinir Ağları (CNN) tabanlı YOLOv8 algoritması kullanarak ilgili cilt hastalıklarının tahmini için mevcut en iyi yaklaşımları seçmek ve hastalıkları sınıflandırmak üzere bir uygulama geliştirilmiştir. Söz konusu çalışmanın planı altı adımdan oluşmaktadır. Bu adımlar sırasıyla; planlama, literatür taraması, verilerin toplanması, model geliştirme, model performansının karşılaştırılması ve sonuçlandırmadan oluşmaktadır. İlk aşamada bilgi sistemlerinin verimli kullanılabilmesi ve araştırma ile en ilgili çalışmaları bulabilmek için arama motoru teknikleri kullanıldı. Araştırma makaleleri, tezler, hastalıklar ile ilgili vaka raporları ayrıntılı bir şekilde incelendi. Söz konusu cilt hastalıkları, yapay zekâ ile ilgili gelişmeler ve sağlıkta yapay zekâ çalışmaları detaylı şekilde araştırıldı. Bu internet araştırmaları sırasında anahtar kelimeler belirlendi ve bu kelimelerin eş anlamlılarıyla oluşturulmuş arama filtreleri uygulandı. Bu filtrelerde 'AND' ve 'OR' mantıksal operatörleri kullanıldı.

İlgili hastalıkların görüntülerinden oluşan veri setini oluşturmak için veri sağlayan açık kaynak kodlu platformlar tarandı. Bu platformlardan, söz konusu hastalıkları içeren veriler bulunarak ayıklanmak üzere derlendi. Uygun derin öğrenme tekniğinin seçilmesi için toplanan makalelerdeki

kullanılan yöntemler incelendi. Literatür çerçevesinde kullanılan başlıca tekniklerin; Yapay Sinir Ağları (ANN), Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Vadeli Bellek (LSTM), Generative Adversarial Networks (GAN) olduğu görülmüştür.

CNN tekniği, Konvolüsyon ve havuzlama katmanları, görüntüdeki düşük seviyeli özellikleri etkili bir şekilde çıkarır. Derin ve geniş katman yapıları sayesinde karmaşık özellikleri öğrenme kapasitesine sahiptir. Bu, özellikle cilt hastalıkları gibi karmaşık sınıflandırma görevlerinde büyük bir avantaj sağlayacağı görüldüğünden uygulama kapsamında CNN tekniğinin kullanılması kararlaştırıldı. CNN modeli kullanarak nesne tespiti yapan ve görüntüdeki çeşitli nesneleri tespit etmeye yarayan YOLO algoritmasının YOLOv8 sürümü modelin eğitim hızı baz alınarak kullanılmaya karar verilmiştir. Tek sınıflı sınıflandırma yöntemi ile RoboFlow ile veri seti hazırlandıktan sonra API yardımı ile veriler Colab ortamına aktararak YOLOv8 modeli için kullanılmıştır. Verilerin az olmasından dolayı modelin small tipi (yolov8s-cls) kullanılmıştır. Şekil 1'de Yolo Sürümleri Performans Karşılaştırma Grafiği verilmiştir.



Şekil 1. YOLO Sürümleri Performans Karşılaştırma Grafiği (Akyon & Jocher, 2024)

2.1. Önerilen Model

2.1.1. RoboFlow ile Veri Seti Oluşturulması ve Veri Setinin Açıklanması


Araştırmada kullanılan veriler, Kaggle platformunda bulunan "DermNet" veri setinden elde edilmiştir (Goel, 2021). Bu veri seti, çeşitli dermatolojik hastalıkların görüntülerini içeren kapsamlı bir koleksiyondur ve orijinal olarak DermNet NZ (dermnet.com) tıbbi veritabanından derlenmiştir. (DermNet, 2024). Veri kümesi Seboreik, Atopik Dermatit, Psoriasis, Onikomikoz hastalığına sahip olan insanların cilt görüntülerini içermektedir. Veri kümesindeki görüntüler yüksek çözünürlüklü olup, jpg formatındadır. Atopic Dermatitis görüntülerinden 113 train, 16 test, 33 valid, Seboreik

görüntülerinden 38 train ve 5 test, 11 valid, Onikomikoz görüntülerinden 88 train ve 12 test, 25 valid, Psoriasis görüntülerinden 85 train ve 12 test, 25 valid verisi içermekte olup, toplam klasör boyutu 16,9 MB'dır. Tablo 1'de veri seti dağılımı bulunmaktadır.

Tablo 1. Veri Seti Dağılımı


Hastalık Türü	Eğitim	Test	Doğrulama	Toplam
Atopik Dermatit	113	16	33	162
Seboreik Dermatit	38	5	11	54
Onikomikoz	88	12	25	125
Psoriasis	85	12	25	122
Toplam	324	45	94	463

Veri setinde Seboreik, Atopik Dermatit, Psoriasis, Onikomikoz hastalıklarının cilt görüntüleri bulunmaktadır. Veri kümesi içerisinde, hastalıklar kendi sınıf isimleriyle etiketlenmiştir. Şekil 2'de veri setinden alınmış olan örnek cilt görselleri bulunmaktadır.



Şekil 2. (a)Psoriasis, (b)Onikomikoz, (c)Seboreik Dermatit, (d)Atopik Dermatit

Bu çalışma kapsamında, veri seti oluşturmak için RoboFlow platformu kullanılmıştır. RoboFlow, sınıflandırma ve nesne algılama projeleri için görüntüleri etiketlemeye yarayan ve veri seti oluşturmak için kullanılan açık kaynaklı ve çevrimiçi bir araçtır. Veri seti oluştururken YOLOv8'de gerçekleştirilecek makine öğrenmesi işleminde verilerin hastalıklara göre etiketlenmesiyle öğreniminin kolaylaştırılması sağlanmıştır. Veri setindeki görsellerde her görselde bir hastalık türü olmasından dolayı tek sınıflı sınıflandırma tipi kullanılmıştır. Görseller sınıflarına göre etiketlendikten sonra veri setine aktarılmıştır. Veri setinin %70'ini eğitim ve %20'i valid ve %10'u test için kullanılmıştır. Şekil 3'te Roboflow ile görüntü sınıflandırma örneği bulunmaktadır.



Şekil 3. RoboFlow ile görüntü sınıflandırma

2.1.2. Veri Ön İşleme

Verileri analiz etmeden önce ön işleme aşamasından geçirilmiştir. Elde ettiğimiz veriler makine öğrenimine sunulmadan önce normalizasyon yapılarak makine açısından daha anlaşılır olması sağlanmıştır. Böylece makinenin performansının artması hedeflenmiştir. Tahmin modeli için görsellerde (640x640) boyutlarında bir standartlaştırma yapılmıştır.

2.1.3. Convolutional Neural Networks (CNN)

CNN olarak adlandırılan Evrişimli Sinir Ağları modeli, görüntü analizinde bugüne kadar kullanılan en etkili model tipidir ve görüntüyü temsil etme ve sınıflandırma yeteneğine sahiptir. Bu ağlar, giriş verilerini küçük bölümlere ayıran evrişim filtrelerini içeren katmanlardan oluşmaktadır (Karaca & Aslan, 2022). CNN üzerine yapılan çalışmalar, 1970'lerin sonlarına, Fukushima'nın 1980'de "denetimsiz öğrenme" yoluyla kendiliğinden organize olan bir ağ yapısı geliştirmesine kadar uzanır (Fukushima, 1980). Bu yapılar, modern ağlara oldukça benzerdir. Daha sonra, (Lo, ve diğerleri, 1995) tarafından medikal görüntü analizinde kullanılmıştır. Derin sinir ağlarındaki temel bir sorun, çok katmanlı yapıların hatalarının geri yayılımıdır. İlk başarılı geri yayılım algoritmaları, (Lecun ve ark., 1998) tarafından posta kutuları üzerindeki yazıları tanımak amacıyla geliştirilmiştir ve bu algoritma 1998'de LeNet modeliyle ilk başarılı gerçek dünya uygulamasını göstermiştir. Ancak, CNN'lerin kullanımı, yeni tekniklerin geliştirilmesi ve hesaplama sistemlerindeki ilerlemelerle birlikte daha verimli bir şekilde eğitilebilir hale gelene kadar yaygınlaşmamıştır. CNN'lerin dönüm noktası, (Krizhevsky ve ark., 2012) tarafından ImageNet yarışmasında büyük bir farkla kazanılan

AlexNet algoritmasıyla gelmiştir. Bu zaferden sonra, CNN'lerin gelişimi hız kesmeden devam etmiştir (Eker & Duru, 2021).

2.1.4. YOLOv8 ile Nesne Sınıflandırma

YOLO, nesne tespiti, sınıflandırma, segmentasyon ve poz tahmini için kullanılan bir algoritmadır. Bu algoritma, adını "You Only Look Once" ifadesinin baş harflerinden alır ve bu ifade "Yalnızca Bir Kez Bak" anlamına gelir. YOLO'nun temelini konvolüsyonel sinir ağları (CNN) oluşturur. Nesne tespiti konusunda daha yüksek doğruluk sunan algoritmalar olmasına rağmen, YOLO'yu diğerlerinden ayıran en önemli özellik hızıdır. YOLO'nun bu kadar hızlı olmasının nedeni, diğer algoritmaların nesne tespiti sırasında ayrı ayrı CNN sınıflandırıcıları kullanarak işlem sayısını artırması ve bunun sonucunda düşük FPS (Frames per Second-saniyede alınan kare sayısı) değerlerine neden olmasıdır. YOLO ise nesne tespitini tek bir regresyon problemi olarak ele alır. Bu işlemde, giriş görüntüsünü $N \times X$ boyutlarında ızgaralara böler. Her ızgara hücresi, kendi alanında bir nesne olup olmadığını belirler ve eğer nesne varsa, bu nesnenin orta noktasında olup olmadığını tespit eder. Eğer nesne ızgaranın merkezindeyse, nesnenin uzunluğu, yüksekliği ve sınıfını tahmin eder. YOLO, her ızgara için ayrı bir tahmin vektörü oluşturur; bu vektörler, nesnenin varlığına dair 1 veya 0 değerini alan bir güven skoru, nesnenin merkezinin x ve y koordinatları (B_x ve B_y), genişliği (B_w) ve yüksekliği (B_h) gibi bilgileri içerir. Bu çalışmada tercih edilen YOLOv8, gerçek zamanlı nesne tespitinde diğer YOLO versiyonlarına göre daha hızlı olması ve doğruluk açısından üstün sonuçlar vermesi nedeniyle en çok kullanılan versiyondur (Karaköse & Aksu, 2023).

Bu çalışmada modelin eğitimi için ultralytics'in 8.0.87 sürümü Google Colab ortamında kurulmuş ve yolov8s-cls modeli kullanılmıştır. Veri sayısının az olmasından dolayı hızlı ve overfitting'i önleyen small model kullanılmıştır. Python'un 3.10.12 sürümü kullanılmıştır. 50 epoch ile model eğitilmiştir. Her epoch'un tamamlanması yaklaşık 2 saniye sürmüştür. Modelde 99 katman kullanılmıştır. Toplam 5,085,860 parametre bulunmaktadır. GPU olarak Tesla T4 kullanılmıştır ve GPU belleği 15GB'dır. Tablo 2'de temel model mimarisi, Tablo 3'te eğitim hiperparametreleri, Şekil 4'te sınıflandırma işleminden örnek çıktılar verilmiştir.

Tablo 2. Temel Model Mimarisi

Model Tipi: YOLOv8s-cls (small model)
Parametre Sayısı: 5,085,860 parametre
Katman Sayısı: 99 katman
Sınıflandırma Başlığı: Global Average Pooling + Tam Bağlantılı (Dense) katmanlar
Giriş Boyutu: 640x640 piksel
Çıkış: 4 sınıflı softmax (atopik, onikomikoz, psoriasis, seboreik)


Tablo 3. Eğitim Hiperparametreleri

Toplam Epoch: 50
Optimizer: Adam
Learning Rate: Otomatik ayarlama (AdamW)
Loss Function: Cross-Entropy
GPU: Tesla T4 (15GB)
Epoch Başına Süre: ~2 saniye
Python Sürümü: 3.10.12
Ultralytics Sürümü: 8.0.87

**Şekil 4.** Sınıflandırma Modelinden Örnek Çıktılar (output)


Karışıklık matrisi, loss (kayıp) ve accuracy (doğruluk) gibi kavramlar, makine öğrenmesi ve derin öğrenme modellerinin performansını değerlendirmek ve optimize etmek için kullanılır. Karışıklık matrisi, bir modelin sınıflandırma performansını detaylı bir şekilde değerlendirmek için kullanılan bir tablodur. Bu matris, modelin tahminlerinin ne kadar doğru olduğunu ve hangi sınıflar arasında karışıklık yaşadığını görsel olarak ortaya koyar. Matriste, modelin tahmin ettiği sınıflar yatay ekseninde, gerçek sınıflar ise dikey ekseninde yer alır. Her bir hücre, belirli bir sınıf için yapılan doğru veya yanlış tahminlerin oranını gösterir. Bu da, modelin sadece genel doğruluğunu değil, aynı zamanda her bir sınıf için ne kadar iyi performans gösterdiğini anlamamızı sağlar. Loss (kayıp) fonksiyonu, modelin tahminleri ile gerçek değerler arasındaki farkı ölçen bir metrik olup, modelin ne kadar hatalı olduğunu gösterir. Eğitim sürecinde modelin performansını optimize etmek için loss fonksiyonu kullanılır. Modelin amacı, bu kayıp fonksiyonunu minimize etmektir. Kayıp fonksiyonunun değeri ne kadar düşükse, modelin tahminlerinin doğruluğu o kadar yüksek demektir. Accuracy (doğruluk), modelin genel başarı oranını ifade eder ve doğru tahminlerin tüm tahminlere oranını gösterir. Bu metrik, özellikle dengeli veri setlerinde modelin genel performansını değerlendirmek için kullanılır. Yüksek bir doğruluk oranı, modelin büyük çoğunlukla doğru tahminler yaptığını gösterir. Ancak, sınıf dağılımı dengesiz olduğunda, accuracy yanıltıcı olabilir, bu nedenle genellikle diğer metriklerle birlikte kullanılır.

3. Bulgular ve Tartışma




Şekil 5. Karışıklık Matrisi

Şekil 5'te karışıklık matrisi (confusion matrix) bulunmaktadır. Karışıklık matrisinde, sınıflandırma modelinin atopic, onikomikoz, psoriasis ve seboreik sınıflarının doğru şekilde ayırt etme yeteneğini değerlendirmek için kullanılmıştır. Matrisin hücrelerindeki yüksek değerler, modelin bu hastalıkları doğru bir şekilde sınıflandırma performansını göstermektedir. "atopic" sınıfı için doğruluk oranı %96, "onikomikoz" için %92, "psoriasis" için %81, ve "seboreik" için %90 olarak belirlenmiştir. Bu oranlar, modelin genel olarak iyi bir performans sergilediğini ve hastalıkları doğru bir şekilde ayırt edebildiğini göstermektedir.




Şekil 6. Eğitim, Validasyon ve Test Doğruluk Değerleri

Şekil 6’da, YOLOv8s-cls modelinin eğitim, validasyon ve test sürecindeki doğruluk değerlerinin gelişimi gösterilmektedir. Mavi çizgi eğitim doğruluğunu, yeşil çizgi validasyon doğruluğunu, kırmızı çizgi ve işaretleyiciler ise test doğruluğunu göstermektedir. Eğitim sürecinin başlangıcında yaklaşık %35 seviyesinde olan doğruluk değerleri, ilk 20 epoch’ta belirgin bir artış göstermiş, sonraki epochlarda daha yavaş bir ilerleme ile stabilize olmuştur. 50. epoch sonunda eğitim doğruluğu %90, validasyon doğruluğu %88.5 ve test doğruluğu %88.3 seviyesine ulaşmıştır.




Şekil 7. Eğitim, Validasyon ve Test Loss Değerleri

Şekil 7’de, modelin eğitim sürecindeki kayıp (loss) değerlerinin değişimi gösterilmektedir. Grafik, 50 epoch boyunca eğitim verisi (kırmızı çizgi), validasyon verisi (mavi çizgi) ve test verisi (yeşil çizgi) üzerindeki kayıp değerlerinin azalma eğilimini göstermektedir. Eğitimin başlangıcında üç veri seti için de kayıp değerleri yaklaşık 1.6-1.7 değerlerinden başlamış ve eğitim ilerledikçe sürekli bir düşüş göstermiştir. İlk 15 epoch’ta belirgin bir düşüş gözlenirken, sonraki epochlarda düşüş hızı azalarak devam etmiştir. 50. epoch sonunda eğitim kaybı yaklaşık 0.15, validasyon kaybı 0.20 ve test kaybı 0.35 değerine ulaşmıştır. Her üç eğrinin 40. epoch’a kadar paralel bir şekilde azalması, modelin dengeli bir öğrenme süreci geçirdiğini göstermektedir. Son epochlarda test kaybında görülen hafif yükseliş, modelin bu noktada optimal performansa ulaştığını ve daha fazla eğitimin aşırı öğrenmeye yol açabileceğini işaret etmektedir.




Şekil 8. Sınıf Bazlı Performans Metrikleri

Şekil 8’de, Sınıf Bazlı Performans Metrikleri grafiğinde modelin dört farklı sınıf (Atopik, Onikomikoz, Psoriasis ve Seboreik) için üç farklı metrik (Precision, Recall ve F1-score) üzerinden değerlendirilmesi gösterilmektedir. Atopik dermatit sınıfı tüm metrikler açısından en yüksek performansı (%95 üzeri) gösterirken, onikomikoz ikinci en iyi performansı (%92 civarı) sergilemektedir. Psoriasis sınıfında özellikle duyarlılık değerinde (%81) bir düşüş gözlenmiş, bu da modelin bazı psoriasis vakalarını diğer sınıflarla karıştırdığını göstermektedir. Seboreik dermatit sınıfı, veri setindeki örnek sayısının azlığına rağmen, tatmin edici bir performans (%89-90) sergilemiştir. Bu metrikler, modelin güçlü ve zayıf yönlerini belirlememize ve gelecekteki iyileştirmeler için odaklanmamız gereken alanları tespit etmemize yardımcı olmaktadır.




Şekil 9. Veri Dengesizliği Analizi

Şekil 9’da, dört farklı cilt hastalığı sınıfının (Atopik, Onikomikoz, Psoriasis ve Seboreik) toplam veri setindeki dağılımlarını hem görüntü sayısı hem de yüzdelik oran olarak göstermektedir. Atopik dermatit sınıfı %35 (162 görüntü) ile en büyük paya sahipken, onikomikoz %27 (125 görüntü), psoriasis %26.3 (122 görüntü) ve seboreik dermatit %11.7 (54 görüntü) oranında temsil edilmektedir. Veri setindeki bu dengesizliğe rağmen, model seboreik dermatit için %90 gibi yüksek bir doğruluk oranı elde etmiştir. Bu sonuç, YOLOv8s-clb model seçiminin, dengesiz veri setlerinde bile etkili sonuçlar sağlayabildiğini göstermektedir.



Şekil 10. YOLO Versiyonları Performans Karşılaştırması

Şekil 10’da, farklı YOLO model versiyonlarının performans karşılaştırması gösterilmektedir. Grafik, YOLOv5-S, YOLOv5-M, YOLOv8-S (kullanılan) ve YOLOv8-M modellerini doğruluk, eğitim hızı (epoch/5) ve parametre sayısı (30M) açısından karşılaştırmaktadır. Mavi sütunlar doğruluk değerlerini, turuncu sütunlar eğitim hızını, kırmızı sütunlar ise parametre sayısını temsil etmektedir. YOLOv8-M modeli parametre sayısı bakımından en yüksek değere sahipken, tüm modeller benzer doğruluk seviyelerine ulaşmıştır. YOLOv8-S (kullanılan) modelinin eğitim hızı diğerlerine göre daha düşük olduğu görülmektedir.



Şekil 11. Literatür Karşılaştırması – Doğruluk Oranları

Şekil 11’de, literatürdeki çeşitli çalışmaların doğruluk oranları ile bu çalışmanın doğruluk oranı karşılaştırılmaktadır. Grafikte görüldüğü üzere, "Bu Çalışma" kategorisinde bulunan çalışmamız %88.3 doğruluk oranına ulaşmıştır. Literatürdeki en yüksek doğruluk oranı Bilgin & Çifci (2021) çalışmasına ait olup %99.7’dir. Bunu sırasıyla Çifci vd. (2014) (%98.0), Codella vd. (2015) (%93.1), ve Harangi (2018) (%89.1) takip etmektedir. En düşük doğruluk oranı ise Rahman vd. (2022) çalışmasına ait olup %65.4 olarak görülmektedir.

4. Sonuçlar ve Öneriler

Bu çalışma kapsamında yapay zekâ ve derin öğrenme tekniklerinin belirli cilt hastalıklarının tahmini konusunda nasıl verimli bir şekilde kullanılabileceğini göstermektedir. Elde edilen yüksek doğruluk oranları, bu tür modellerin klinik uygulamalarda kullanılma potansiyelini ortaya koymaktadır. Bu çalışmada kullanılan YOLOv8 modeli, Seboreik, Atopik Dermatit, Psoriasis ve Onikomikoz hastalıklarını doğru bir şekilde sınıflandırabilmiştir. Model, test veri setinde %88.3 genel doğruluk oranına ulaşmıştır. Hastalık sınıfları bazında incelendiğinde, Atopik Dermatit için %96 doğruluk, %95.6 hassasiyet (precision) ve %96.1 duyarlılık (recall) değerleriyle en yüksek F1 skoru (%95.8) elde edilmiştir. Onikomikoz hastalığı için %92 doğruluk, %91.8 hassasiyet ve %92.0 duyarlılık değerleriyle %91.9 F1 skoru sağlanmıştır. Psoriasis için %81 doğruluk, %86.2 hassasiyet ve %80.9 duyarlılık değerleriyle %83.5 F1 skoru elde edilirken, Seboreik Dermatit için %90 doğruluk, %89.1 hassasiyet ve %90.0 duyarlılık değerleriyle %89.5 F1 skoru kaydedilmiştir. Modelin doğruluk skoru yüksek olup, modelin genel performansını göstermektedir.

Çalışmada veri ön işleme aşamasında sadece görüntü boyutları açısından (640x640) normalizasyon yapılmıştır. Bu yaklaşım modelin eğitim performansını artırmış olmakla birlikte, ışık koşulları, renk değişimleri ve kontrast farklılıkları gibi görüntü kalitesini etkileyen diğer faktörler normalize edilmemiştir. Bu durum, farklı çekim koşullarında alınmış görüntülerde model performansını etkileyebilecek bir sınırlılık oluşturmaktadır. Gelecek çalışmalarda, görüntü iyileştirme teknikleri ve kapsamlı normalizasyon yöntemleri kullanılarak bu sınırlılığın giderilmesi, modelin gerçek klinik ortamlardaki farklı görüntü kalitesi koşullarına daha iyi adapte olmasını sağlayabilir.

Geliştirilen model, klinik ortamlarda çeşitli uygulama potansiyeline sahiptir. Özellikle dermatoloji kliniklerinde triaj aracı olarak, tele-dermatoloji uygulamalarında ön tanı desteği sağlamak için, tıp eğitiminde vaka tanıma yeteneğini güçlendirmek için ve dermatoloji uzmanlarına erişimin sınırlı olduğu bölgelerde yardımcı araç olarak kullanılabilir. Bununla birlikte, modelin klinik uygulamalarda bazı sınırlılıkları da bulunmaktadır. Model şu aşamada sadece nihai tanı aracı olarak değil, tanı sürecinde yardımcı bir araç olarak değerlendirilmelidir. Çalışmada sadece dört cilt hastalığı ele alınmış olup, dermatolojik hastalıkların geniş spektrumu düşünüldüğünde modelin kapsamının genişletilmesi gerekmektedir. Ayrıca, veri setinin farklı cilt tonları, yaş grupları ve hastalık şiddetlerini yeterince temsil etmemesi, modelin genellenebilirliğini sınırlayabilir. Kompleks ve atipik vakalarda performans düşüşü yaşanabileceği ve görüntü kalitesine olan bağımlılık da göz önünde bulundurulmalıdır.

Bu uygulama, yapay zekâ tabanlı sistemlerin hastalıkların teşhisi konusunda önemli ölçüde yarar sağlayabileceğini gösteren yüksek tahmin oranlarını yakalayarak, hastalık teşhisi konusunda hastalara genel bir fikir vererek doktorlara yardımcı olma potansiyelini ortaya koymuştur. Gelecekte yapılacak çalışmalarda, veri sayısı artırımı ve model mimarisinde yapılacak iyileştirmelerle birlikte epoch ve batch sayılarının optimizasyonu ile daha güçlü hesaplama kaynaklarında daha yüksek doğruluk ve F1 skorlarına sahip modellerin geliştirilebileceği sonucuna varılmıştır. Ayrıca, daha geniş ve çeşitli veri setleri kullanarak daha fazla hastalık türünü tanıyabilen, klinik ortamlarda kapsamlı şekilde test edilmiş modellerin geliştirilmesi gelecekteki araştırmaların odak noktası olmalıdır.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Akyon, F. Ç., & Jocher, G. (2024, 08 30). *YOLOv8 Genel Bakış*. ultralytics: <https://docs.ultralytics.com/tr/models/yolov8/> adresinden alındı
- Bilgin, G., & Çifci, A. (2021). Eritematöz Skuamöz Hastalıkların Teşhisinde Makine Öğrenme Algoritmalarının Etkisi. *Journal of Intelligent Systems: Theory and Applications*, s. 195-202.
- Chovatiya, R. (2023). Atopic Dermatitis (Eczema). *JAMA*, s. 268.
- Codella, N., Cai, J., Abedini, M., Garnavi, R., Halpern, A., & Smith, J. R. (2015). Deep learning, sparse coding, and svm for melanoma recognition in dermoscopy images. *International Workshop on Machine Learning in Medical Imaging, Springer*, s. 118-126.
- Çifci, A., İlkuçar, M., Bozkurt, M. R., & Uyaroğlu, Y. (2014). Liken planus ve Sedef Deri Hastalıklarının Çok Katmanlı Yapay Sinir Ağı Kullanılarak Sınıflandırılması. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, s. 30-36.
- Çilhoroz, Y., & Işık, O. (2021). Yapay Zekâ: Sağlık Hizmetlerinden Uygulamalar. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, s. 573-588.
- DermNet. (2024). *Dermatology Image Database*. Dermnet: <https://dermnetnz.org/> adresinden alındı
- Dorynska, A., & Spiewak, R. (2012). Epidemiology of skin diseases from the spectrum of dermatitis and eczema. *Malays J Dermatol*, s. 1-11.
- Eker, A. G., & Duru, N. (2021). Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *Acta Infologica, Volume 5, Number 2*, s. 406-474.
- Fonacier, L. S., Dreskin, S. C., & Leung, D. Y. (2010). Allergic skin diseases. *Journal of Allergy and Clinical Immunology*, s. 138-149.
- Fukushima, K. (1980). Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position . *Biological Cybernetics*, s. 193-202.
- Goel, S. (2021). *Dermnet*. Kaggle: <https://www.kaggle.com/datasets/shubhamgoel27/dermnet> adresinden alındı
- Gül, M., & Çiftçi, İ. (2022). Onikomikoz ve Tedavi Yaklaşımları. *Sağlık Akademisi Kastamonu*, s. 587-612.
- Harangi, B. (2018, October). Skin lesion classification with ensembles of deep convolutional neural networks. *Journal of Biomedical Informatics*, s. 25-32.
- Havlickova, B., Czaika, V., & Friedrich, M. (2008). Epidemiological trends in skin mycoses worldwide. *Mycoses*, s. 2-15.
- Hay, R. J. (2011). Malassezia, dandruff and seborrhoeic dermatitis: an overview. *British Journal of Dermatology*, s. 2-8.
- Hazarika, I. (2020, July). Artificial intelligence: opportunities and implications for the health workforce. *International Health*, s. 241-245.
- Karaca, Y. E., & Aslan, S. (2022). Birbirine Benzeyen Üç Farklı Hastalığın Tespitinde Derin Öğrenme Modellerinin Performansı. *Journal of New Results in Engineering and Natural Science, No:17*, s. 35-47.
- Karaköse, E., & Aksu, M. (2023). İnsansız Hava Araçlarında Nokta Bulutu Verisi Kullanılarak İniş Pisti Uygunluk Analizi. *Fırat Üniversitesi Müh. Bil. Dergisi*, 535-551.
- Koo, T., Kim, M., & Jue, M.-S. (2021). Automated detection of superficial fungal infections from microscopic images through a regional convolutional neural network. *PLoS ONE*.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, s. 1097-1105.
- Kurd, S. K., & Gelfand, J. M. (2009). The prevalence of previously diagnosed and undiagnosed psoriasis in US adults: results from NHANES 2003-2004. *Journal of the American Academy of Dermatology*, s. 218-224.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *PROC OF THE IEEE*.
- Lo, S., Lou, S., Lin, J., Freedman, M., Chien, M., & Mun, S. (1995). Artificial convolution neural network techniques and applications for lung nodule detection. *IEEE Trans Med Imaging*, s. 14(4):711 - 718.
- Lyons, F., & Ousley, L. E. (2014). Dermatology for the advanced practice nurse. *Springer Publishing Company*.
- Lyons, F., & Ousley, L. E. (2014). Dermatology for the advanced practice nurse. *Springer Publishing Company*.
- Öztürk, M., & Şahin, M. (2018). Yapay Zeka: Kavramlar Teoriler ve Uygulamalar. *Bilişim Teknolojileri Dergisi*, s. 85-95.
- Rahman, M. A., Reynolds, J., Dangott, B., Villegas, D. M., Nassar, A., & Akkus, Z. (2023). Classification of fungal genera from microscopic images using artificial intelligence. *Journal of Pathology Informatics*.
- Rasheed, A., Umar, A. I., Shirazi, S. H., Khan, Z., Nawaz, S., & Shahzad, M. (2022). Automatic eczema classification in clinical images based on hybrid deep neural network. *Computers in Biology and Medicine*, s. 147.
- Tamer, E., Ilhan, M. N., Polat, M., Lenk, N., & Alli, N. (2008). Prevalence of skin diseases among pediatric patients in Turkey. *The Journal of dermatology*, s. 413-418.