



Makale / Research Paper

Derin Sinir Ağları Kullanılarak Koyun-Keçi Çiçeği Hastalığının Tespiti ve Sınıflandırılması için Hibrit Bir Yaklaşım

Nilgün ŞENGÖZ^{1a}

¹Burdur Mehmet Akif Ersoy Üniversitesi, MAKÜ-BAKA Teknokent Koordinatörlüğü
Burdur/Türkiye
nilgunsengoz@mehmetakif.edu.tr

Received/Geliş:09.08.2022

Accepted/Kabul: 07.09.2022

Öz: Yapay zeka, ve bunun alt dalları olan makine öğrenimi ve derin öğrenme medikal görüntüleme sistemlerinden yüz tanıma, otonom sürüş gibi bir çok farklı alanlarda kendini ispat etmiştir. Özellikle derin öğrenme modelleri günümüzde çok popüler olmuştur. Derin öğrenme modelleri yapısı itibarıyla çok karmaşık olduğundan ötürü doğası gereği kara-kutu modellerine en iyi örneklerden birisidir. Bu durum yorumlanabilirlik ve açıklanabilirlik bağlamında son kullanıcıyı şüphe içerisinde bırakmaktadır. Bu nedenle, bu tür sistemlerin anlaşılabilir metotların açıklanabilir yapay zeka (AYZ) ile yapılması ihtiyacı son yıllarda araştırmacılar tarafından yaygın olarak bahsedilmektedir. Bu çalışma özelinde, CLAHE metodu kullanılarak hibrit bir metot üzerinde durulmuş olup popüler derin öğrenme algoritmaları bu metot ile birleştirilmiştir. Çalışma neticesinde yeni ve orijinal veri kümesi üzerinde sınıflandırma çalışması gerçekleştirilmiş olup sınıflandırma doğruluğu %99,643 ile VGG16 mimarisi üzerinden Grad-CAM uygulaması gerçekleştirilmiş ve CLAHE metodu ile ön işlenen görüntülerin ısı haritaları çıkarılmıştır. Bu bağlamda, CLAHE metodu ile Açıklanabilir Yapay Zeka metodu ilk defa birlikte kullanılmış ve literatüre önemli bir katkı sağlanmıştır.

Anahtar Kelimeler: derin öğrenme, CLAHE, açıklanabilir yapay zeka, koyun-keçi çiçek hastalığı

A Hybrid Approach for Detection and Classification of Sheep-Goat Pox Disease Using Deep Neural Networks

Abstract: Artificial intelligence and its sub-branches, machine learning and deep learning, have proven themselves in many different fields such as medical imaging systems, face recognition, autonomous driving. Especially deep learning models have become very popular today. Because deep learning models are very complex in nature, they are one of the best examples of black-box models. This situation leaves the end user in doubt in terms of interpretability and explainability. For this reason, the need for such systems to be made with understandable methods and explainable artificial intelligence (XAI) has been widely mentioned by researchers in recent years. In this study, a hybrid method was focused on using the CLAHE method and popular deep learning algorithms were combined with this method. As a result of the study, classification study was carried out on the new and original dataset, Grad-CAM application was carried out on the VGG16 architecture with classification accuracy of 99.643% and heat maps of the pre-processed images were obtained with the CLAHE method. In this context, the CLAHE method and the Explainable Artificial Intelligence method were used together for the first time and an important contribution was made to the literature.

Keywords: deep learning, CLAHE, explainable artificial intelligence, goat-sheep pox

How to cite this article

Şengöz N., "Derin Sinir Ağları Kullanılarak Koyun-Keçi Çiçeği Hastalığının Tespiti ve Sınıflandırılması için Hibrit Bir Yaklaşım", El-Cezeri Journal of Science and Engineering, 2022, 9 (4); 1542-1554.

Bu makaleye atıf yapmak için

Şengöz N., "Derin Sinir Ağları Kullanılarak Koyun-Keçi Çiçeği Hastalığının Tespiti ve Sınıflandırılması için Hibrit Bir Yaklaşım", El-Cezeri Journal of Science and Engineering, 2022, 9 (4); 1542-1554.

ORCID: *0000-0001-5651-8173

1. Giriş

Koyun-keçi çiçeği ateş, özellikle akciğerlerde ölümle sonuçlanan koyun ve keçilerin viral hastalıklarından birisidir. Bulaşıcı niteliği taşıyan bu hastalık türü Türkiye’de yaygın olmakla beraber Burdur ilinde de özellikle sıklıkla görülmektedir. Öyle ki koyun ve keçilerde görülen çiçek hastalığı %18,4 oranı ile 2. önceliğe sahip bir hastalık türüdür [1]. Bu bağlamda hastalığın erken teşhis ve tanısı önem arz etmekte olup bununla ilgili hastalığın tanısında özellikle histopatolojik muayene gelmektedir. Ve fakat uzun histopatolojik muayene süreci, patoloğun deneyimi ve hastalığın bulaşıcı olmasından ötürü zaman kısıtı, bu süreci bilgisayarlı ortama aktarmak ve patoloğlara yardımcı olacak şekilde düzenleme gereği doğmuştur. Bu çalışmada özellikle orijinal veri kümesi kullanılmış, sisteme hibrid bir bakış açısı kazandırarak veri ön işleme olarak CLAHE metodundan sonra farklı özellikte derin sinir ağları algoritmaları kullanılarak en uygun ve sınıflandırma doğruluğu en yüksek algoritma seçilmiş ve bu algoritmada açıklanabilir yapay zeka tekniklerinden biri olan Grad-CAM metodu uygulanmıştır.

Hastalığın histopatolojik görüntülerinin bilgisayar ortamında sınıflandırılması, patoloğlara hızlı tanı ve teşhis imkanı sunmaktadır. Yapay zeka (YZ), özellikle tıbbi görüntüleme alanında ciddi başarı göstermektedir. Özellikle patoloğlara yardımcı olmak için, Tam Slayt Görüntüleri (Whole Slide Imaging-WSI) adı verilen tüm slayt tarayıcıları tarafından üretilen dijital görüntüler, patoloğlara histopatolojik tanı ve teşhiste yardımcı olmaktadır. Ancak artan görüntü sayısı, zaman kısıtlaması ve patoloğun tanı koymadaki tecrübesi nedeniyle bu süreç uzar ve erken tanı ve tedavi gerektiren olgularda sorun yaratır. Bu bağlamda yapay zeka devreye girmekte ve histolojik görüntülerin sınıflandırılması için çeşitli teknikler geliştirilmiştir. Genel olarak, YZ destekli bir histopatoloji görüntü analizi, eğitim ve test aşamaları olarak ikiye ayrılır. Eğitim bölümünde, yapay zeka ağının daha önce etiketlenmiş görüntüler kullanılarak eğitilmesi ve ardından ağa daha önce verilmeyen yeni görüntüler üzerinden sınıflandırma yapılması beklenmektedir. Bu süreçte derin öğrenme gibi modeller üzerinde bir çalışma yapılıyorsa eğitim aşamasında ön işleme yapılması hibrid bir metodoloji sağlanmasından ötürü önemlidir. Eğitim aşamasında ağa öğretilen görüntüler üzerine kurulan yapı esas alınarak test aşamasında ağa daha önce verilmeyen görüntüler kullanılır ve bu yapının sınıflandırma haritası üretmesi beklenir. Sonuç olarak, sınıflandırmadan kaynaklanan nicel analiz sonuçları karşılaştırılır ve patoloğa yardımcı olacak bir sonuç üretilir. Yapay zeka yöntemleri, bilgisayarla görme ile ilgili ciddi şekilde başarılı sonuçlar elde edilmektedir [2, 3, 4, 5].

Tıbbi sınıflandırma tanı iş akışında, yapay zeka nicel olarak yüksek sınıflandırma doğruluğuna sahip olsa da yorumlanabilirlik ve açıklanabilirlik açısından bu teknolojileri gerçek dünya iş akışı modellerine yansıtma bazı zorluklar yaratmaktadır. Derin öğrenme modellerinde kara kutu modellerinin doğası gereği bulunması nedeniyle, bu kararların nasıl alındığına yönelik açıklanabilir yöntemlerin geliştirilmesi, kullanıcı odaklı güven üzerine algoritmaların kullanılabilirlik düzeyini artırmaktadır. Açıklanabilir YZ (AYZ), YZ çözümlerini daha güvenilir ve yorumlanabilir hale getirme bağlamında Makine Öğrenimi modellerinin tahminlerine daha yakından bakmamızı sağlar.

Bu nedenle, bu yöntem özellikle patoloğların YZ destekli bir modelin nasıl ve neden karar verdiğini netleştirmelerine yardımcı olur.

Bu çalışma özelinde CLAHE metodu kullanılarak ilk öncelikle veri ön işleme gerçekleştirilmiştir. CLAHE metodu sonrası ise derin öğrenme tekniklerinden DenseNet, EfficientNetB0, VGG16, InceptionV3, MobileNet ve MobileNetV2 kullanılmıştır. En iyi doğruluk oranı gösteren sınıflandırma algoritmasına açıklanabilir bir hale getirmek için Grad-CAM metodu uygulanmıştır. Böylece patoloğa yardımcı olması amaçlanmıştır.

Makale şu şekilde düzenlenmiştir; 2. bölüm, konuyla ilgili yapılan literatür özeti yer almaktadır. Bölüm 3, sınıflandırma için derin öğrenme materyal metoda odaklanır. Bölüm 4, bulgular ve tartışmayı içerir. Bölüm 5'te ise sonuç ve öneriler kısmı yer almaktadır.

2. Literatür Özeti

Dijital patoloji (DP), yüksek çözünürlüklü görüntüler üretmek için histoloji slaytlarının dijitalleştirildiği süreçtir. Tıbbi görüntüleme araştırmaları alanında çok popüler hale gelmektedir. Mikroskobik dijital görüntülerin bir bilgisayar programına aktarılmasıyla erken tanı ve tedavi yöntemleri geliştirilebilmekte, bu sayede hem patoloğlara hem de hastalara büyük faydalar sağlanmaktadır. Bu nedenle histopatoloji görüntüleme uygulamaları hızlı ve etkili olmaları nedeniyle araştırma çevrelerinde büyük ilgi görmektedir. Mikroskobik görüntülerin patoloğlar tarafından laboratuvar ortamında dijital ortama aktarılması ile hastalık tespiti, bölütleme ve sınıflandırma problemlerinde Yapay Zeka algoritmalarının kullanılması sağlanmıştır.

Radyoloji görüntülerinin aksine histopatolojik görüntüler, her görüntüde içerdikleri doku, renk ve şekil gibi bilgilerden dolayı sınıflandırma aşamasında karmaşık bir yapıya sahiptir. Histopatoloji görüntü analizi için bilgisayarla görme üzerine yapılan araştırmalar ise, [6]'da doku görüntülerini otomatik algılama ve sınıflandırma sorunlarıyla ilgili değerli bulgular (ESA) kullanan bir sınıflandırıcı geliştirilmiştir. Önerdikleri yöntem hem ikili hem de çok sınıflı sınıflandırma için umut verici sonuçlar elde etmiştir. [7]'de, lenf nodu bölümünün histopatoloji görüntülerini sınıflandırmak için çift kanallı bir artık evrişim sinir ağı geliştirilmiştir. Kanserli ve kanserli olmayan tümörleri ayırt etmek için ikili sınıflandırma yapmışlardır. [8]'da kolorektal kanserin histopatolojik görüntü sınıflandırması için yeni bir yöntem önerilmiştir. Bu makalede önerilen model ile kolorektal kanser görüntülerini sekiz farklı sınıfa ayırarak geleneksel ESA'dan daha iyi performans göstermiştir. [9]'da histopatolojik görüntülerin sınıflandırılmasında veri ön işleme tekniklerinden biri olan CLAHE metodunun kullanılmasıyla sınıflandırma doğruluk oranının yükseldiği gözlemlenmiştir.

Son yıllarda, derin sinir ağlarının doğası gereği kara-kutu modellerine sahip olduğundan ötürü karar verme süreci büyük ölçüde belirsiz ve insanlar için anlaşılması zor olduğu için araştırmacılar Açıklanabilir YZ'ya odaklanmaktadır. [10]'da paratüberküloz hastalığına dair derin öğrenme algoritmaları kullanılarak sınıflandırma metodları incelenmiş ve Grad-CAM uygulaması kullanılarak patoloğlar üzerinde detaylı bir anket çalışmasına yer verilmiştir. Bu çalışma bilgisayar nasıl görür, insan nasıl görür üzerine yapılan anket sonucunda bilgisayar-insan etkileşimi açısından literatüre önemli bir katkı sunmuştur. [11]'de, dahili ağ durumları kullanılarak her pikselin öneminin ne kadar belirgin olduğunu gösteren kara kutu modelinden önem haritası oluşturmak için farklı yöntemler kullanılmıştır. Ayrıca, görüntüleri girdi olarak alan ve bir sınıf olasılığı çıkaran derin sinir ağları için AYZ sorununu ele almaktadır. [12]'de meme kanseri teşhisinde histopatolojik görüntüler kullanılarak sınıflandırma gerçekleştirilmiş ve Grad-CAM metodu uygulanarak bu durum desteklenmiştir.


[13]'te, transkriptomik verilerden doku tiplerini tahmin etmek için önceden eğitilmiş modeller üzerinden tahmin oranı en yüksek olanı tespit edilmiş ve bu duruma en çok katkı sağlayan genler belirlenmiştir. Sonuçların yorumlanabilirliği geliştirmek için çok katmanlı algılayıcı (MLP) ve evrişimli sinir ağı (CNN) mimarileri kullanılarak açıklanabilir makine öğrenimi modellerini kullanarak biyolojik mekanizmaları keşfetmek için yeni bilgiler sağlamaktadır. Talha vd. [14] Gastrointestinal hastalığına dair endoskopik görüntülerden hastalık tespiti için yapay zeka tabanlı doktorların da kullanabileceği bir model önermiştir. Evrişimli sinir ağlarını kullanan bu model, kararların hekimler tarafından güvenilir kılınması ve bu sorunun üstesinden gelinebilmesi için Açıklamaları Yapay Zeka teknikleri uygulanmıştır. Bu makalede orijinal ve yeni bir veri kümesi

kullanıldığından ötürü daha önce böyle bir çalışma yer almamakla beraber bu çalışmada ayrıca hibrit bir metot benimsenmiş olup CLAHE ver ön işlemeyle Açıklanabilir Yapay Zeka metotlarından biri olan Grad-CAM uygulaması birleştirilmiştir. Böylece literatüre önemli bir katkı sağlayacağı düşünülmüştür.

3. Materyal ve Metot

3.1. Orijinal Veri Kümesi

Bu çalışma için hastalığa dair orijinal bir veri kümesi oluşturulmuştur. Burdur Mehmet Akif Ersoy Üniversitesi, Patoloji Anabilim Dalı tarafından oluşturulan bu veri kümesi, 150 adet hasta, 127 adet ise sağlıklı koyun ve keçilerden alınan histopatolojik ciğer kesitlerinden oluşmaktadır. Şekil 1.'de görüleceği üzere hasta ve sağlıklı kesitlere ait histopatolojik görüntüler yer almaktadır.



Şekil 1. Hastalıklı ve Sağlıklı ciğer kesitlerine dair histopatolojik görüntüler

Bu veri kümesi oluşturulurken bu hastalık neticesinde ölmüş hayvanlardan alınan ciğer kesit örnekleri kullanıldığından ötürü herhangi bir etik kurul iznine ihtiyaç duyulmamıştır.

3.2. Derin Öğrenme Algoritmaları ve Grad-CAM Metodu

Derin öğrenme, büyük miktarda veri üzerinde karmaşık hesaplamalar yapmak için yapay sinir ağlarını kullanır. İnsan beyninin yapısına ve işlevine göre çalışan bir tür makine öğrenmesidir. Sağlık, e-ticaret, eğlence ve reklamcılık gibi endüstriler genellikle derin öğrenme algoritmalarını kullanır. Eğitim süreci sırasında, algoritmalar özellikleri çıkarmak, nesnelere gruplandırmak ve faydalı veri kalıplarını keşfetmek için girdi dağılımındaki bilinmeyen öğeleri kullanır. Derin öğrenme modelleri birkaç algortmadan yararlanır. Tek bir ağ mükemmel kabul edilmese de bazı algoritmalar belirli görevleri gerçekleştirmek için daha uygundur. Bu bağlamda derin öğrenme algoritmalarından DenseNet, EfficientNetB0, VGG16, InceptionV3, MobileNet ve MobileNetV2 kullanılarak yeni ve orijinal veri kümesi üzerinde sınıflandırma çalışmaları yapılmış ve sınıflandırma doğruluğu en yüksek olan algortmada Grad-CAM metodu uygulanmıştır.


3.2.1. Veri Ön İşleme Metodu

Görüntü iyileştirmede sıklıkla kullanılan histogram eşitleme, görüntünün histogramını kullanarak kontrast ayarının görüntü işleminde bir yöntemdir. Bu yöntem, özellikle görüntü dar bir yoğunluk değerleri aralığı ile temsil edildiğinde, genellikle birçok görüntünün genel kontrastını artırır. Bu ayarlama sayesinde, yoğunluklar, tüm yoğunluk aralığını eşit şekilde kullanarak histogram üzerinde daha iyi dağıtılabilir. Bu, daha düşük yerel kontrastlı alanların daha yüksek bir kontrast kazanmasına izin verir. Histogram eşitleme bunu, görüntü kontrastını azaltmak için kullanılan yüksek yoğunluk değerlerini etkin bir şekilde yayararak gerçekleştirir. Ancak, histogram eşitleme tüm görüntünün yoğunluk dağılımını kullandığından, ortalama yoğunluk orta olarak ayarlandığında bu, bazı görüntülerde soluk bir etkiye neden olabilir. Dar bir bölgede kalabalık yoğunluk dağılımına

sahip görüntülerde ise çok sayıda gürültü pikselinin oluşmasına neden olabilir. Bu sorunları çözmek için yerel histogram eşitleme teknikleri geliştirilmiştir [15].

Uyarlanabilir histogram eşitleme (Adaptive Histogram Equalization-AHE), değiştirilmiş bir histogram eşitleme işlemidir ve yerel veriler üzerinde optimizasyon gerçekleştirir. Buradaki ana fikir, görüntünün ızgara şeklinde dikdörtgen bölgelere bölünmesi ve her bölgeye standart histogram eşitlemesinin uygulanmasıdır. Optimum bölge boyutları ve sayısı görüntüye göre değişir. Kontrast sınırlı uyarlanabilir histogram eşitleme (Contrast Limited Adaptive Histogram Equalization-CLAHE), kontrastın aşırı yükseltilmesiyle ilgilenen uyarlanabilir histogram eşitlemenin (AHE) bir çeşididir. CLAHE, görüntünün tamamı yerine, görüntüde döşeme adı verilen küçük bölgeler üzerinde çalışır. Komşu karolar daha sonra yapay sınırları kaldırmak için çift doğrusal enterpolasyon kullanılarak birleştirilir. Bu algoritma, görüntülerin kontrastını iyileştirmek için uygulanabilir [16].


Bu bağlamda yeni oluşturulan veri kümesine veri ön işleme tekniklerinden biri olan CLAHE metodu uygulanmış olup Şekil 2’de hasta ve sağlıklı histopatolojik görüntülere bu metot uygulandıktan sonraki halleri gösterilmektedir.



Şekil 2. CLAHE metodu uygulandıktan sonraki histopatolojik görüntüler

3.2.2. DenseNet Mimarisi

DenseNet, tüm katmanları (eşleşen özellik haritası boyutlarıyla) doğrudan birbirine bağlanan Yoğun Bloklar (Dense Blocks) aracılığıyla katmanlar arasında yoğun bağlantılar kullanan bir tür evrimsel sinir ağıdır. İleri beslemeyi korumak için, her katman önceki tüm katmanlardan ek girdiler alır ve kendi özellik haritalarını sonraki tüm katmanlara iletir [17].

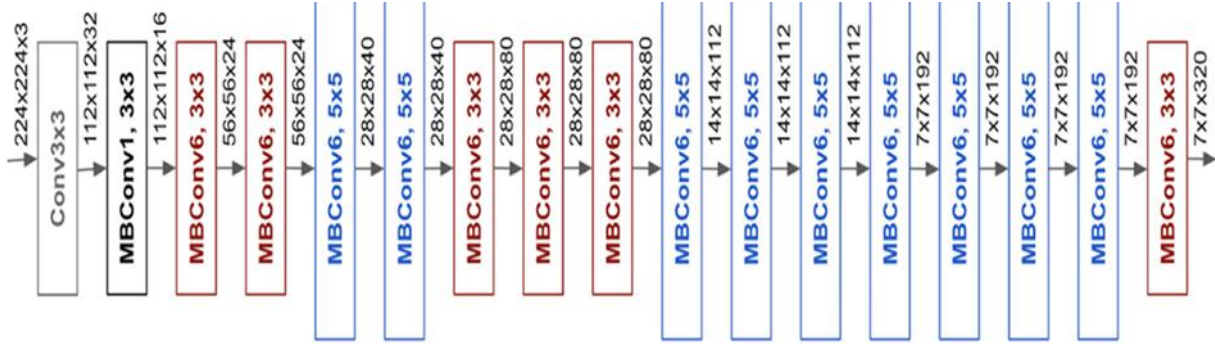


Şekil 3. DenseNet Mimarisi [17]

3.2.3. EfficientNetB0 Mimarisi

EfficientNet, bir bileşik katsayı kullanarak tüm derinlik/genişlik/çözünürlük boyutlarını tek tip olarak ölçekleyen bir evrimsel sinir ağı mimarisi ve ölçekleme yöntemidir. Bu faktörleri isteğe


bağlı olarak ölçeklendiren geleneksel uygulamanın aksine, EfficientNet ölçeklendirme yöntemi, ağ genişliğini, derinliğini ve çözünürlüğünü bir dizi sabit ölçeklendirme katsayısıyla eşit şekilde ölçeklendirir [18].



Şekil 4. EfficientB0 Mimarisi [19]

3.2.4. VGG16 Mimarisi


VGG16, evrişimli bir sinir ağı, bir tür yapay sinir ağı olan ConvNet olarak da bilinir. Evrişimli bir sinir ağı, bir girdi katmanına, bir çıktı katmanına ve çeşitli gizli katmanlara sahiptir. VGG16, bugüne kadarki en iyi bilgisayarlı görü modellerinden biri olarak kabul edilen bir tür evrişimli sinir ağıdır. Bu modelin tasarlayıcıları, ağları değerlendirip ve çok küçük (3 × 3) evrişim filtrelerine sahip bir mimari kullanarak derinliği arttırmış; bu, önceki tekniklere ait konfigürasyonlarda önemli bir gelişme göstermiştir [20].



Şekil 5. VGG16 Mimarisi

3.2.5. InceptionV3 Mimarisi


Inception v3, görüntü analizine ve nesne algılamaya yardımcı olan için evrişimli bir sinir ağıdır ve GoogLeNet için bir modül olarak başlamıştır. Başlangıçta ImageNet Tanıma Yarışması sırasında tanıtılan, Google'ın Inception Evrişimsel Sinir Ağı'nın üçüncü baskısıdır. Inceptionv3'ün tasarımı, parametre sayısının çok fazla büyümesini engellerken daha derin ağlara izin vermeyi amaçlar, AlexNet için 60 milyona kıyasla "25 milyonun altında parametreye" sahiptir. ImageNet'in sınıflandırılmış görsel nesnelerin bir veritabanı olarak düşünülebileceği gibi, Inception da bilgisayarlı görme dünyasında nesnelerin sınıflandırılmasına yardımcı olur. Inceptionv3 mimarisi birçok farklı uygulamada yeniden kullanılmıştır ve genellikle ImageNet'ten "önceden eğitilmiş" olarak kullanılmıştır [21].



Şekil 6. Inception V3 Mimarisi [21]

3.2.6. MobileNet Mimarisi

MobileNet, Görüntü Sınıflandırma ve Mobil Görüş için bir evrişimli sinir ağı mimarisi modelidir. Başka modeller de vardır, ancak MobileNet'i özel yapan şey, transfer öğrenmeyi çalıştırmak veya uygulamak için çok daha az hesaplama gücüne sahip olmasıdır. Gömülü sonuçların doğruluğundan önemli ölçüde ödün vererek GPU'su veya düşük hesaplama verimliliği olmayan sistemler ve bilgisayarlar için, bu onu Mobil cihazlar için mükemmel bir uyum sağlamasına yol açar. Tarayıcıların hesaplama, grafik işleme ve depolama konusunda sınırlamaları olduğundan, web tarayıcıları için de en uygundur. MobileNet'in çekirdek katmanı, Derinlemesine Ayrılabilir Evrişim olarak adlandırılan, derinlemesine ayrılabilir filtrelerdir. Ağ yapısı, performansı artırmak için başka bir faktördür. Genişlik ve çözünürlük, gecikme ve doğruluk arasında değiş tokuş yapmak için ayarlanabilir [22].



Şekil 7. MobileNet Mimarisi [23]

3.2.7. Grad-CAM Metodu

Grad-CAM, kara kutu modellerini yorumlamak için bir başka popüler ve etkili tekniktir. Görüntüdeki hangi bölgelerin belirli bir sınıfla alakalı olduğunu göstermektedir. Görüntüdeki dikkat bölgelerini görselleştirmek için, son sınıflandırma katmanından önceki sondaki tam bağlantılı katmanlar yerine bir GAP katmanı kullanılır ve ağ, çıktıları üretmek için global ortalama havuzlama katmanı aracılığıyla evrişimli özellik haritalarını her bir sınıf için girdi olarak alır. Bu nedenle, sınıf ayrımlı yerelleştirme haritası, bir evrişim katmanının özellik haritalarına göre gradyanı hesaplanarak elde edilir [24].

3.2.8. Performans Değerlendirmesi

Performans ölçümleri, her makine öğrenimi hattının bir parçasıdır. İlerleme kaydedip kaydedilmediğini belirtir ve nicelik bir değer üretir. Tüm makine öğrenimi modelleri, performansı değerlendirmek için bir metriğe ihtiyaç duyar. Karışıklık matrisi, bir sınıflandırma algoritmasının performansını tanımlamak için kullanılan bir tablodur. Bir karışıklık matrisi, bir sınıflandırma algoritmasının performansını görselleştirir ve özetler. Bu çalışma özelinde karışıklık matrisi kullanılarak niceliksel performans ölçütleri üzerinden derin öğrenme modelleri değerlendirilmesi gerçekleştirilmiştir. Karışıklık matrisi, sınıflandırıcının ölçüm metriklerini tanımlamak için kullanılan dört temel özellikten oluşur. Bunlar; TP (Gerçek Pozitif/True Positive) uygun şekilde hastalığa sahip olan hasta sayısını temsil eder. TN (Doğru Negatif/True Negative) doğru

sınıflandırılmış sağlıklı hasta sayısını temsil eder. FP (Yanlış Pozitif/False Positive) hastalığa sahip yanlış sınıflandırılan hasta sayısını temsil eder, ancak aslında sağlıklıdır. FN (Yanlış Negatif/False Negative) yanlış olarak sağlıklı olarak sınıflandırılan ancak aslında hastalıktan muzdarip olan hasta sayısını temsil eder. Bir algoritmanın performans ölçütleri, yukarıda belirtilen TP, TN, FP ve FN temelinde hesaplanan doğruluk, kesinlik, geri çağırma ve F1 puanıdır.

Bir algoritmanın doğruluğu, doğru sınıflandırılmış hastaların (TP+TN) toplam hasta sayısına (TP+TN+FP+FN) oranı olarak temsil edilir. Bir algoritmanın kesinliği, hastalığı olan doğru sınıflandırılmış hastaların (TP) hastalığa sahip olduğu tahmin edilen toplam hastalara (TP+FP) oranı olarak temsil edilir. Duyarlılık metriği, doğru sınıflandırılmış hastalıklı hastaların (TP) gerçekte hastalığı olan toplam hasta sayısına oranı olarak tanımlanır. F1 puanı, F Ölçüsü olarak da bilinir. F1 puanı, kesinlik ve duyarlılık arasındaki dengeyi belirtir.

Alıcı işletim özellikleri (ROC) eğrisi, çeşitli eşik değerleri için duyarlılık ve FP oranı arasındaki grafiklerdir. Eğrinin altındaki alan (AUC), bu ROC eğrisinin altındaki alandır; bir sınıflandırma modelinin kalitesini ölçmek için kullanılır. Alan ne kadar büyük olursa, performans o kadar iyi olur. AUC, tüm olası sınıflandırma eşiklerinde toplu bir performans ölçüsü sağlar. AUC değeri 0 ile 1 arasındadır. Tahminleri %100 yanlış olan bir modelin AUC değeri 0'dır; tahminleri %100 doğru olan birinin AUC değeri 1'dir.

4. Bulgular ve Tartışma


Bu çalışmada orijinal ve yeni bir veri kümesi olan koyun-keçi çiçek hastalığına ait histopatolojik görüntüler kullanılarak derin öğrenme algoritmalarında sınıflandırma işlemi gerçekleştirilmiştir. Derin öğrenme algoritmalarına görüntüler verilmeden önce veri ön işleme tekniklerinden biri olan CLAHE yöntemi kullanılmıştır.

Ayrıca, sınırlı bir veri kümesi olduğundan ötürü derin öğrenme modellerini değerlendirmek için çapraz doğrulama (cross-validation) kullanılmıştır. Çapraz doğrulama, kullanılmayan veriler üzerinde bir makine öğrenimi modelinin becerisini tahmin etmek için öncelikle uygulamalı makine öğreniminde kullanılır. Yani, modelin eğitimi sırasında kullanılmayan veriler üzerinde tahminlerde bulunmak için kullanıldığında modelin genel olarak nasıl performans göstermesinin beklendiğini tahmin etmek için sınırlı bir örnek kullanılmaktadır. k değeri 10'a sabitlenmiştir; bu değer, genellikle düşük sapmalı bir varyansa sahip bir model beceri tahminiyle sonuçlanmak üzere deney yoluyla bulunmuştur.


Tablo 1. Derin Öğrenme Algoritmalarının Performans Değerleri

	AUC	F1	Kesinlik	Duyarlılık	Sınıflandırma
		(%)	(%)	(%)	Doğruluğu (%)
DenseNet121	0,979	0,940	0,957	0,942	94,180
EfficientB0	0,955	0,887	0,926	0,912	89,206
VGG16	1,0	0,996	0,997	0,996	99,643
InceptionV3	0,889	0,80	0,835	0,823	82,275
MobileNet	0,995	0,992	0,986	0,985	98,545
MobileNetV2	0,974	0,966	0,943	0,931	93,148

Tablo 1'de de görüleceği üzere VGG16 modeli en iyi sınıflandırma oranına sahiptir. Bu bağlamda Şekil 8'de VGG16 modeline ait karışıklık matrisi yer almaktadır.



Şekil 8. VGG16 modeli karışıklık matrisi



Şekil 9. VGG16 modeli ROC eğrisi

Şekil 9'da verilen ROC eğrisi, t eşliğinin değişen değerleri için x eksenindeki (özgüllük) karşısında y eksenindeki bir duyarlılık grafiğidir. (0,0)'ı (1,1)'e bağlayan 45° diyagonal çizgi, rastgele karşılık gelen ROC eğrisidir. Altın standardı için ROC eğrisi (0,0) ile (0,1) ve (0,1) ile (1,1) arasındaki çizgidir. Genel olarak, ROC eğrileri bu 2 uç arasında yer alır. ROC eğrisinin altındaki alan, test değerleri spektrumu boyunca tanısal doğruluğun esasen ortalamasını alan bir özet ölçüdür.


Açıklanabilir yapay zeka bilgisayar-insan etkileşimi için derin öğrenme algoritmalarının çıktılarına dair güven duyulması ve algoritmanın nereye neden odaklandığına dair bir çıktı üretmesi bakımından patoloğa yardımcı olacak ısı haritaları üretmektedir. Yukarıda da bahsi geçen Grad-CAM algoritması bu tür bir ısı haritalama metodlarından popüler olanlarından biridir.

Tablo 1'de görüleceği üzere diğer algoritmalara nazaran VGG16 mimarisi performans metriklerinden en yüksek değeri aldığından ötürü Grad-CAM algoritmasını yani açıklanabilir yapay zeka metodunu bu algoritma üzerinde oluşturulmuştur. Görüntülerin daha şeffaf ve açıklanabilir olması için, önerilen VGG-16'nın eğitilmiş ağırlıkları, bilgisayarın nasıl gördüğüne, yani görüntülerin derin öğrenme algoritmalarında eğitimden sonra nasıl sınıflandırıldığına odaklanan bir algoritma olan Grad-CAM'e dahil edilmiştir.

Grad-CAM, bir CNN algoritmasının son evrişim katmanı tarafından üretilen özellik haritalarını kullanır. Son evrişim katmanlarının, üst düzey anlambilim ve ayrıntılı uzamsal bilgi arasında en iyi açıklamaya sahip olması beklenir. Kara kutu modelinin kutusundan çıkarılması tıbbi görüntü analizi için çok önemlidir. Birçok yapay zeka algoritması, bir kararın nasıl ve neden verildiğine dair herhangi bir kanıt sağlayamaz. Bu nedenle, bu çalışmada kara kutu modelini yorumlamak için Grad-CAM tekniği benimsenmiştir.

Şekil 10 hastalıklı ve sağlıklı histopatolojik görüntülerin CLAHE metodu uygulandıktan sonra en iyi sınıflandırma performansına sahip VGG16 algoritmasının Grad-CAM çıktılarını göstermektedir. Grad-CAM tekniği, görüntüdeki hangi bölgelerin belirli bir sınıfla ilgili olduğunu görmek için kullanılır. Kırmızı renk, görüntünün o sınıfa özgü ayırt edici kısımlarını belirtir. Bu çalışma derin öğrenmede yorumlanabilirlik ve açıklanabilirlik üzerine yoğunlaşmıştır.

Farklı derin öğrenme algoritmaları üzerinden yeni ve orijinal veri kümesi çalıştırılmış ve en iyi sınıflandırma doğruluğuna sahip olan model Grad-CAM uygulaması için seçilmiştir. Çıktısı alınan bu çalışma uzman patoloğlara da gösterilmiş olup, onların da görüşleri alınmıştır. Bilgisayarın doğru yerlere odaklandığını belirten patoloğlar, sistemin okunabilir bir formatta açıklanabildiğini ispat etmektedir.



Şekil 10. Grad-CAM görüntü çıktıları

5. Sonuç ve Öneriler

Modelleri tanımak ve gelecekteki olaylar hakkında doğru tahminler yapmak için verilerden öğrenen sistemlerin geliştirilmesi olan makine öğrenimi, sağlık hizmetlerini dönüştürmek için büyük bir potansiyele sahiptir. Makine öğrenimi tabanlı araçlar, karmaşık klinik karar vermeyi destekleyebilir ve sağlık çalışanlarının zamanını boşa harcayabilecek ve iş memnuniyetsizliğine neden olabilecek birçok rutin görevi otomatikleştirebilir. Veri güvenliği ve gizliliği ile ilgili sorunlar, matematiksel modellerin düşük performansı veya yüksek doğruluğa sahip modellerin kara-kutu görevi görmesi, araçları iş akışına entegre etme zorluğu, sağlık profesyonelleri arasında makine öğrenimi tabanlı çözümlerin düşük kabul edilebilirliği ve bu çözümlerin nasıl değerlendirileceğiyle ilgili belirsizlik, bu çözümlerin benimsenmesinin önündeki engeller olabilir. Burada bahsi geçen kara-kutu kelimesi anlamsal olarak gözlemlenebilirlik eksikliği olarak tanımlanabilir. Derin öğrenme ağları gibi gizli katmanların çok sayıda olduğu algoritmalarda kara-kutu modellerine sahip olduğu için son kullanıcıya açıklama ve güven eksikliği yaratmaktadır.

Derin öğrenme teknikleri makine öğrenimi aksine yüksek doğruluk performansına sahip bir algoritmadır. Bu bağlamda derin öğrenme birçok farklı alanda önemli gelişmeler göstermiş ve performansını kanıtlamıştır. Ve fakat derin öğrenme doğası gereği kara-kutu sistemlerine sahip olduğundan ötürü, sisteme verilmiş olan bir yığın veriden sonuçsal olarak her ne kadar doğru yanıtlar verse de bu sonuçları neye istinaden verdiği konusunda hala açık bir kapı bulunmaktadır.

Bu bağlamda, derin öğrenme modellerini kara-kutu'dan cam-kutu'ya çevirmek için sonuçların görselleştirilmesi özellikle medikal sektörler gibi kritik öneme sahip alanlarda önem arz etmektedir. Çalışma hem CLAHE metodunu hem de derin öğrenme algoritmalarını kullanarak hibrit bir yöntem izlemiştir. Sonuçlara bakıldığı zaman en iyi sınıflandırma doğruluğu olarak VGG16 mimarisi ile %99,643 ile diğer modellerden daha iyi bir performans sergilemiştir. Kara-kutu modelinin Grad-CAM metodu ile görselleştirilmesiyle görüntülere açıklanabilirlik kazandırılmıştır.

Bu bağlamda açıklanabilir yapay zeka metotlarından biri olan Grad-CAM uygulaması VGG16 mimarisi üzerinde çalıştırılmış ve anlamlı ısı haritaları elde edilmiştir. Daha sonra patolojlara gösterilen bu görüntüler olumlu tepkiler almıştır. Böylece derin öğrenme algoritmasının sağlanması gerçekleştirilmiştir.

Teşekkür

Bu çalışmanın gerçekleştirilmesi için desteklerini esirgemeyen Prof. Dr. Özlem Özmen'e ve Prof. Dr. Tuncay Yiğit'e teşekkür ederim.

Yazarın Katkıları

NŞ çalışmaları yapmış ve makalenin yazımını gerçekleştirmiştir. Yazar makalenin son halini okudu ve onayladı.

Çıkar Çatışması

Yazar(lar), çıkar çatışması olmadığını beyan eder

Kaynaklar

- [1]. Ayhan, V., Taşkın, T., İnce, D., Yılmaz, M., Boyar, S., Bardakçioğlu, E., “Damızlık koyun-keçi yetiştiricileri birliklerinin edinimleri”, *İlik Kong*, 68, 2010
- [2]. Jiang, Y., Chan, C. K., Chan, R. C., Wang, X., Wong, N., To, K. F., Poon, C. C., Identification of Tissue Types and Gene Mutations from Histopathology Images for Advancing Colorectal Cancer Biology, *IEEE Open Journal of Engineering in Medicine and Biology*, 2022, 3: 115–123
- [3]. Saldanha, O. L., Quirke, P., West, N. P., James, J. A., Loughrey, M. B., Grabsch, H. I., Kather, J. N., Swarm learning for decentralized artificial intelligence in cancer histopathology, *Nature Medicine*, 2022, 1-8
- [4]. Abdelsamea, M. M., Zidan, U., Senousy, Z., Gaber, M. M., Rakha, E., Ilyas, M., A survey on artificial intelligence in histopathology image analysis, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2022, e1474
- [5]. Sauter, D., Lodde, G., Nensa, F., Schadendorf, D., Livingstone, E., & Kukuk, M., Validating Automatic Concept-Based Explanations for AI-Based Digital Histopathology, *Sensors* 2022, 22(14), 5346
- [6]. Roy, K., Banik, D., Bhattacharjee, D., ve Nasipuri, M., Patch-based system for Classification of Breast Histology images using deep learning, *Comput. Med. Imaging Graph*, 2019, 71, 90–103
- [7]. Chakraborty, S., Aich, S., Kumar, A., Sarkar, S., Sim, J.S., Kim, H.C., “Detection of cancerous tissue in histopathological images using Dual-Channel Residual Convolutional Neural Networks (DCRCNN)”, *22nd International Conference on Advanced Communication Technology (ICACT)*, 197–202, 2020
- [8]. Wang, C., Shi, J., Zhang, Q., Ying, S., “Histopathological image classification with bilinear convolutional neural networks”, *39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 4050– 4053, 2017
- [9]. Şengöz, N., Yiğit, T., Özmen, Ö., Isik, A.H., Importance of Preprocessing in Histopathology Image Classification Using Deep Convolutional Neural Network, *Advances in Artificial Intelligence Research*, 2022, 2(1), 1-6
- [10]. Yiğit, T., Şengöz, N., Özmen, Ö., Hemanth, J., Işık, A.H., Diagnosis of Paratuberculosis in Histopathological Images Based on Explainable Artificial Intelligence and Deep Learning, *Traitement du Signal*, 2022, 39(3), 863-869
- [11]. Petsiuk, V., Das, A., Saenko, K., “RISE: Randomized Input Sampling for Explanation of Black-box Models”, *Br. Mach. Vis. Conf.* 2018
- [12]. Graziani, M., Andrearczyk, V., Müller, H., “Visualizing and interpreting feature reuse of pretrained CNNs for histopathology”, In *Irish Machine Vision and Image Processing Conference (IMVIP 2019)*, Dublin, Ireland, 2019
- [13]. Zhao, Y., Shao, J., Asmann, Y. W., Assessment and optimization of explainable machine learning models applied to transcriptomic data, *Genomics, Proteomics&Bioinformatics*, 2022
- [14]. Saeed, T., Loo, C. K., & Kassim, M. S. S., Ensembles of deep learning framework for stomach abnormalities classification, *CMC-Computers Materials & Continua*, 2022, 70(3), 4357-4372
- [15]. Yoon, H., Han, Y, Hahn, H., Image Contrast Enhancement based Sub-histogram Equalization Technique without Over-equalization Noise, *International Journal of Computer Science and Engineering*, 2009, 3(2)
- [16]. Yadav, G., Maheshwari, S., Agarwal, A., “Contrast limited adaptive histogram equalization based enhancement for real time video system”, *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2392-2397, 2014
- [17]. Lodhi, B., Kang, J., Multipath-DenseNet: A Supervised ensemble architecture of densely connected convolutional networks, *Information Sciences*, 2019, 482,63-72

- [18]. Tan, M., Le, Q.V., “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks”, Proceedings of the 36th International Conference on Machine Learning, 6105–6114, 2019
- [19]. Theckedath, D., Sedamkar, R. R., Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks, SN Computer Science, 2020, 1(2), 1-7
- [20]. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A., “Going deeper with convolutions”, In Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9, 2015
- [21]. Li, J., Wang, P., Li, Y.Z., Zhou, Y., Liu, X.L., Luan, K., “Transfer learning of pre-trained inception-V3 model for colorectal cancer lymph node metastasis classification”, IEEE International Conference on Mechatronics and Automation, 1650–1654, 2018
- [22]. Sinha, D., El-Sharkawy, M., “Thin MobileNet: An Enhanced MobileNet Architecture”, IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON), 0280-0285, 2019
- [23]. Sahlol, A.T., Abd Elaziz, M., Tariq Jamal, A., Damaševičius, R., Farouk Hassan, O., A Novel Method for Detection of Tuberculosis in Chest Radiographs Using Artificial Ecosystem-Based Optimisation of Deep Neural Network Features, Symmetry, 2020, 12(7),1146
- [24]. Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., Batra, D., “Grad-CAM: Visual explanations from deep networks via gradient-based localization”, IEEE International Conference on Computer Vision (ICCV), 618-626, 2017