

Akciğer Kanseri Tespitinde Sınıf Aktivasyon Haritaları Kullanarak Açıklanabilir Derin Öğrenme Modeli ve Radyolog Değerlendirmesi

Savaş TUNÇER^{1*}, Oğuzhan KATAR², Tülin ÖZTÜRK³, Özal YILDIRIM⁴

¹ Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; ORCID: [0000-0003-2455-5388](https://orcid.org/0000-0003-2455-5388)

² Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; ORCID: [0000-0002-5628-3543](https://orcid.org/0000-0002-5628-3543)

³ Elazığ Fethi Sekin Şehir Hastanesi, Radyoloji Bölümü, Elazığ, Türkiye; ORCID: [0000-0001-8942-5264](https://orcid.org/0000-0001-8942-5264)

⁴ Yapay Zeka ve Veri Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; ORCID: [0000-0001-5375-3012](https://orcid.org/0000-0001-5375-3012)

* Corresponding Author: savastuncer62@gmail.com

Received: 24 July 2024; Accepted: 16 October 2024

Reference/Atf: S. Tunçer, O. Katar, T. Öztürk, and Ö. Yıldırım, “Akciğer Kanseri Tespitinde Sınıf Aktivasyon Haritaları Kullanarak Açıklanabilir Derin Öğrenme Modeli ve Radyolog Değerlendirmesi”, Researcher, vol. 04, no. 02, pp. 166–175, 2024.

Özet



Akciğer kanseri dünya genelinde yaygın ve ölümcül olan kanser türlerinden biridir. Akciğer kanserinin erken tanısı, hastalığın tedavi edilebilir aşamada tespit edilmesine olanak tanır ve bu da hastanın yaşam şansını önemli ölçüde artırır. Yapay zekânın bu alanda kullanımı, bir dizi avantaj sağlayarak hastalığın daha etkili bir şekilde tespitine yardımcı olabilir. Son zamanlarda derin öğrenme yaklaşımları görüntü sınıflandırma çalışmalarında baskın bir rol almaktadır. Derin öğrenme yöntemlerinin en önemli dezavantajlarından birisi kapalı-kutu yapısı nedeniyle güvenilirlik açısından şeffaflık eksikliğidir. Bu amaçla açıklanabilir modeller önemli bir araştırma haline gelmiştir. Açıklanabilir derin öğrenme modelleri, genellikle sınıf aktivasyon haritaları (Class Activation Maps - CAM) gibi tekniklere dayanmaktadır. Bu çalışmada, akciğer kanseri tespitinde açıklanabilir bir derin öğrenme modeli oluşturulmuştur. Model içerisinde grad-CAM, score-CAM, faster score-cam gibi bazı önemli sınıf aktivasyon teknikleri ile ısı haritaları elde edilmiştir. Makale kapsamındaki deneysel çalışmalar, akciğer bilgisayarlı tomografi (BT) görüntülerini içeren ve açık erişimli bir veri seti olan IQ-OTHNCCD veri seti üzerinde yürütülmüştür. Sınıflandırma aşamasında konvolüsyonel sinir ağları (KSA) tabanlı ResNet101V2, VGG16, MobileNetV2, DenseNet201 ve EfficientNetB0 modelleri kullanılmıştır. Deneysel sonuçlara göre EfficientNetB0 modeli %98.63 ile en yüksek sınıflandırma doğruluğuna ulaşmıştır. Sınıflandırıcı modele uygulanan farklı CAM teknikleri ile ısı haritaları elde edilmiştir. Elde edilen ısı haritaları uzman radyolog tarafından değerlendirilerek sonuçlar tartışılmıştır. Şekil 1’de örnek bir model çıktısı gösterilmiştir.

Anahtar Kelimeler: Akciğer kanseri, Açıklanabilir derin öğrenme, Konvolüsyonel sinir ağları

Explainable Deep Learning Model and Radiologist Evaluation Using Class Activation Maps in Lung Cancer Detection

Abstract

Lung cancer is one of the common and widespread cancer types worldwide. Early diagnosis of lung cancer makes it possible to detect it at an individually treatable stage, which significantly increases the scope of life offered. The use of artificial intelligence in this area can help detect it more effectively, providing a number of advantages. Recently, deep learning treatments have been making their appearance and are taking a dominant role. One of the most important risks of deep learning methods is the lack of transparency in terms of reliability due to their closed-box structure. These intended explicable models have become an important research topic. Explainable deep learning models are generally based on techniques such as Class Activation Maps (CAM). An explainable deep learning model for detecting lung cancer in these patients. Heat maps were obtained with some important class activation techniques in the model, such as grad-CAM, Score-CAM, Fast Score-Cam. The individual samples in the article are run on the IQ-OTHNCCD dataset, an open-access dataset containing lung computed tomography (CT) images. In the classification phase, convolutional neural networks (CNN) based ResNet101V2, VGG16, MobileNetV2, DenseNet201 and EfficientNetB0 models were used. The highest outputs of 98.63% were found in

the EfficientNetB0 model spent experimentally. Heat maps were obtained with different CAM techniques applied to the classifier model. The resulting heat maps were evaluated by a specialist radiologist and the results were examined.

Keywords: Lung cancer, Explainable deep learning, Convolutional neural networks

1.Giriş

Dünya çapındaki kanser ölümlerinin neredeyse dörtte biri akciğer kanserinden kaynaklanmaktadır ve bu hastalık, hem erkeklerde hem de kadınlarda kanserden ölümlerin önde gelen nedenidir. Yakın tarihlere kadar bilinmeyen bir hastalıkta meydana gelen yüksek artışın nedenleri birçok araştırmanın konusu olmuştur. Başlıca nedenleri olarak, sanayinin neden olduğu gaz ve tozlardan kaynaklanan artan hava kirliliği; yolların asfaltlanması; taşıt trafiğindeki artış; Birinci Dünya Savaşı'nda gaza maruz kalma; 1918'deki grip salgını ve benzen veya benzinle çalışmak görülmüştür. Ancak akciğer kanseri, daha az otomobilin, daha az sanayinin, daha az asfalt yolun olduğu ülkelerde ve benzen veya benzine maruz kalmayan işçilerde aynı oranda arttığı görüldüğünde, araştırmalar başka etkenleri arama üzerine yoğunlaşmıştır [1]. Son zamanlarda sigara içmekten bir olasılık olarak bahsedilmektedir. Tümör metastazlarının çok çeşitli olması veya tanı anında hasta sağlığının kötü olması nedeniyle cerrahi rezeksiyonun gerçekleştirilmesi çoğu zaman imkânsızdır [2]. Akciğer kanseri taraması, radyoterapi, cerrahi teknikler ve sistemik tedavideki son gelişmeler, tanı, tedaviye karar verme ve nüks değerlendirmesinde artan karmaşıklığa yol açmıştır. Akciğer kanserinde hayatta kalmanın en önemli belirleyicisi tanı anında hastalığın evresidir, bu nedenle erken tanı için etkili bir tarama yöntemi geliştirmek, akciğer kanseri bakımında uzun vadeli bir hedef olmuştur. Son on yılda, büyük klinik çalışmaların sonuçlarına dayanarak, yüksek riskli bireylerde düşük doz bilgisayarlı tomografi (LDCT) kullanılarak akciğer kanseri tarama programları bazı klinik ortamlarda uygulanmıştır [3].

Yapay zekâ, karmaşık algoritmalar ve yazılımlar kullanarak, karmaşık verilerin analizinde, yorumlanmasında ve anlaşılmasında insan bilişini taklit etme yeteneğine sahiptir ve şu anda çeşitli sağlık hizmetlerinde başarıyla uygulanmaktadır. Akciğer kanserinin değerlendirmesinde oluşan sorunlara karşı yapay zekâ tabanlı tahmin modelleri geliştirilmektedir ve yapay zekânın gelecekte tarama, teşhis, tedavi seçimi ve kurtarma tedavisine ilişkin karar vermede rol oynayabileceği görülmektedir. Yapay zekânın görüntülerdeki bilgiyi nicelleştirme yeteneğinden ve insanlarla karşılaştırıldığında görüntülerdeki karmaşık modelleri tanıma konusundaki üstün yeteneğinden yararlanan yapay zeka, akciğer kanseri taraması ortamında elde edilen LDCT görüntülerinin yorumlanmasında klinik çalışanlarına yardımcı olma potansiyeline sahiptir. Son on yılda akciğer kanseri tespitini iyileştirmeyi amaçlayan çeşitli yapay zekâ modelleri geliştirilmiş ve bazı algoritmalar, iyi huylu akciğer nodüllerini kötü huylu akciğer nodüllerinden ayırma konusunda deneyimli radyologlarla eşit, hatta onlardan daha iyi performans göstermiştir [3]. Görüntüleme, akciğer kanseri yönetiminin tüm bileşenleri için gereklidir ve yapay zekâ uygulamalarında önemli bir rol oynama potansiyeline sahiptir. Yapay zekâ, akciğer kanseri tanısı, tedavisi ve yanıt değerlendirmesinde prognostic biomarker keşfinde kullanılarak, onu kişiselleştirilmiş tıpta önemli bir noktaya getirmiştir [4]. Bununla birlikte, keşif çalışmaları potansiyel faydayı gösterse de, yapay zekânın klinik karar vermede kullanılabilmesi için önce sıkı doğrulama ve standardizasyona ihtiyaç vardır.

Makine öğrenimi, bileşen içinde daha önce yapılan tahminlere dayalı olarak akıllı öğrenmenin gerçekleşmesini sağladığı için yapay zekâ yazılımını bir adım daha ileriye taşımaktadır. Yazılım, ilerledikçe karmaşık karar verme süreçlerini gerçekleştirir ve önceki faaliyetlerden öğrenir. Farklı Makine öğrenimi algoritmaları kullanılarak akciğer kanseri tespitine dayalı araştırmalar yapılmaktadır. Karar Ağacı, Naive Bayes ve yapay sinir ağı gibi algoritmaları karşılaştırmak için tahmine dayalı veri madenciliği algoritmalarını kullanarak akciğer kanseri hastalarında ameliyat sonrası yaşam beklentisinin tahmin edilmesiyle ilgilenilmiş, KNN, SVM, NN ve Lojistik Regresyon gibi sınıflandırıcılar uygulanarak karşılık gelen doğruluk oranları elde edilmektedir [5]. Bilgisayarlı tomografi (BT) görüntüleme, akciğer kanseri tanısı ve tespiti için kullanılan etkili bir tıbbi tarama testidir. Doktorlar elde edilen BT görüntülerini akciğer dokularını analiz etmek ve teşhis etmek için kullanır. Derin öğrenme, veri temsillerinin öğrenilmesi söz konusu olduğunda yüksek düzeyde soyutlama elde etmek için birden fazla işlem katmanından oluşan özel bir makine öğrenimi türüdür. Yaygın olarak makine öğrenimi yaklaşımının bir dalı ve bir derin öğrenme sınıfı olarak bilinen Evrişimli Sinir Ağı (CNN),

günümüzde birçok görüntü bölümlene yaklaşımının yerini almaktadır [6]. BT görüntüleri üzerinde tıbbi görüntü segmentasyonu için derin öğrenme tekniklerinin uygulanması, büyük miktarda veriyi hızlı ve doğru bir şekilde öğrenme ve işleme yetenekleri nedeniyle büyük ilgi görmektedir.

Derin öğrenme yöntemleri kullanılarak BT görüntüleri içeren datasetler üzerinde sınıflandırma ve segmentasyon işlemlerinin yapılması birçok çalışmaya konu olmuştur. Kullanılan datasetler içerisinde LIDC öne çıkan datasetlerden biridir. Amerikan Ulusal Sağlık Enstitüsü Vakfı tarafından açık kaynak olarak sunulan, The Lung Image Database Consortium (LIDC) kelimesinin kısaltmasından oluşan ve Türkçe karşılığı Akciğer Görüntü Veritabanı Konsorsiyumu adlı dataset içerisinde 2000 adet CT görüntüsü bulunmaktadır. Yokota et al., (2014) [7] tarafından yapılan çalışmada Pulmoner nodüllerin buzlu camla opaklık tespiti (GGO) yönteminde kullanmak amacıyla yapay zekâ algoritmalarını LIDC dataset üzerinde uygulamışlardır. Yapay sinir ağı (ANN) kullanılarak oluşturulan otomatik algoritma sayesinde 82,1% TP, 6,7% FP oranı elde edilmiştir.

Mhaske et al., (2019)[8] tarafından yapılan çalışmada Bilgisayar Destekli Teşhis (CAD) sisteminin değerlendirmesi yapılmış ve BT görüntüleri üzerinde segmentasyon, özellikle çıkarma ve sınıflandırma işlemleri CNN-LSTM adlı bir hibrit yapay sinir ağı kullanılarak yapılmıştır. Önceden işlenip bölümlere ayrılan görüntüler üzerinde CNN aracılığıyla özellik çıkarımı, LSTM modeli üzerinde tahmin ve sınıflandırma gerçekleştirilmiştir. LIDC veri tabanı üzerinden yapılan bu çalışmada 97% oranına erişen bir doğruluk tespit edilmiştir.

Otomatik akciğer kanseri tespiti ve sınıflandırması (ALCDC) sistemi BT görüntüleri üzerinde tümörlerin tespit edilmesi ve sınıflandırılması için tasarlanmış, LIDC datasetinin kullanıldığı çalışmada veriler test edilmiş ve %97,2 doğruluk, %95,6 duyarlılıkla en iyi sonuçlar elde edilmiştir [9].

LDNNET, softmax sınıflandırıcıyı birleştiren convnet'lere dayalı uyarlanabilir bir mimari olup LIDC-IDRI dataseti üzerinde kullanılmış datasetin eğitimi sonucunda doğruluk oranı 0.982072 kadar ulaşmıştır [10].

Akciğer kanserini incelemek için İşaretleyici Kontrollü Havza, Bölge Büyümesi ve İşaretleyici Kontrollü Kaplamalı Havza adlı üç görüntü segmentasyon yaklaşımı LIDC dataset üzerine Random Forest Ensemble ve RUSBoost yöntemleri uygulanarak değerlendirilmiş sonuç olarak doku eğitim veri seti için en yüksek doğruluğu sağladığı görülmüştür [11].


Derin öğrenme modellerinin kapsadıkları çok sayıda katmandan dolayı karmaşıklık düzeyleri yüksektir. Bu durum onların yorumlanmasını zorlaştırmaktadır. Herhangi bir CNN tabanlı modeli görsel açıklamalar üretmek daha şeffaf hale getirmek için yeni bir sınıf ayırıcı yerleştirme tekniği olan Gradyan ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) tekniği son dönemlerde kullanılmaya başlamıştır. Grad-CAM, görüntülerdeki önemli bölgeleri vurgulamak için ağırlıklar (grad ağırlıklar) olarak degradeleri (meyil) kullanır [12] Grad-CAM görselleştirmelerin sınıflar arasında daha doğru bir şekilde ayırım yapabilmekte, bir sınıflandırıcının güvenilirliğini daha iyi ortaya çıkarabilmekte ve veri kümelerindeki yargıların belirlenmesine yardımcı olabilmekte ve görüntü sınıflandırma, görüntü alt yazılama ve VQA dâhil olmak üzere çeşitli kullanıma hazır mimariler Grad-CAM 'e geniş çapta uygulanabilmektedir[13]. BT görüntüleri üzerinden COVID-19 tespitini renkli görselleştirme olarak sunmak amacıyla Grad-CAM tekniği uygulanmış ve böylece çalışma sonuçlarının yorumlanması kolaylaşmıştır[14].

Score-CAM Pertürbasyon tabanlı ve CAM tabanlı yöntemler arasındaki boşluğu dolduran ve aktivasyon haritalarının ağırlığını sezgisel olarak anlaşılır bir şekilde türeten yeni bir gradyan içermeyen görsel açıklama yöntemidir [15]. Pertürbasyon teorisi, tam olarak çözümlenemeyen bir problemin, bu probleme bağlı başka bir problem çözümünün kullanılarak matematiksel açıklamasının yapılması olarak tarif edilebilir. Score-CAM, her aktivasyon haritasının ağırlığı için *güven artışı* kullanır, eğimlere olan bağımlılığı ortadan kaldırır ve daha makul bir ağırlık temsiline sahiptir [16]. BT görüntüleri üzerinde COVID-19 tespiti için denetlenemeyen öğrenme + rasgele kırpma, denetlenemeyen öğrenme + merkez kırpma gibi teknikler Score-CAM kullanılarak yapılabilmektedir [17].

2. Materyal ve Yöntem

2.1. Veri Seti

Bu çalışmada Irak-Onkoloji Eğitim Hastanesi/Ulusal Kanser Hastalıkları Merkezi (IQ-OTH/NCCD) 'den 2019 yılından toplanan akciğer kanseri veri seti [18] kullanılmıştır. Data Set kanseri tanısı konmuş hastaların BT taramalarından oluşmaktadır. Data sette 1098 görüntü bulunmakta ve bu görüntüler benign (iyi huylu) ve malignant (kötü huylu) olmak üzere iki sınıfta toplanmaktadır. Data set eğitiminde iki ayrı sınıftaki veriler 20% test ve 80% train olarak ayrılarak model eğitimi yapılmıştır. Şekil 1'de kullanılan veri seti içerisindeki sınıflara ait bazı örnek görüntüler verilmiştir.



Şekil 1: Akciğer kanseri veri seti içerisindeki bazı örnek görüntüler

2.2. Önerilen Tespit Modeli

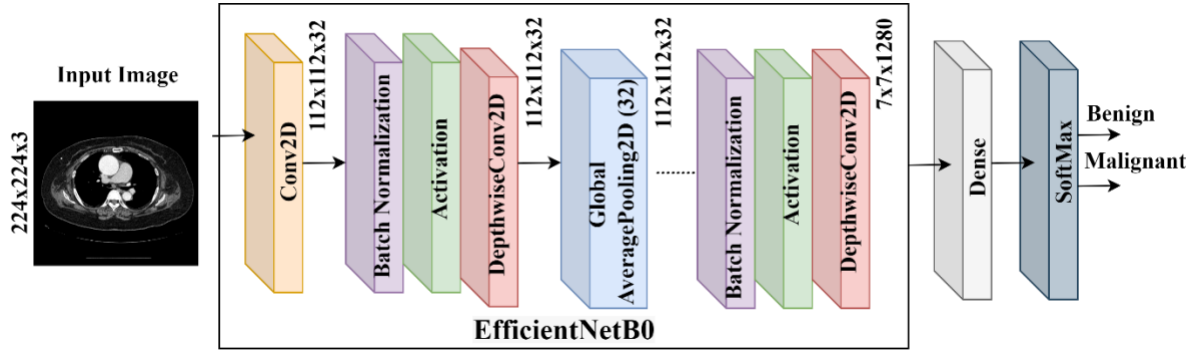
Konvolüsyonel sinir ağları (KSA) derin öğrenmeyle birlikte yapay zeka içerisinde yer alan bir kavramdır. Yapısında filtrelerle girdiden özellikleri çıkaran konvolüsyon katmanı, hesaplama performansı boyutunu azaltmak için bir havuzlama katmanı ve bir sinir ağı katmanı [19] bulunmaktadır. KSA modelleri bu tarz katmanların parametrelerin ayarlanarak birleştirilmesiyle oluşturulmaktadır. Bu çalışmada baştan bir model kurmak yerine transfer öğrenme yaklaşımı uygulanmıştır. Büyük veri kümeleri üzerinde eğitilen ResNet101V2, VGG16, MobileNetV2, DenseNet201 ve EfficientNetB0 modelleri ile deneysel çalışmalar gerçekleştirilmiştir. Model doğrulukları arasında kıyaslama yapıldığında EfficientNetB0 modeli en yüksek sınıflandırma doğruluğuna ulaşılmıştır. EfficientNet verimliliği artırmak için kullanılan bir modeldir. Kullanılan parametre sayılarının değişmesiyle B0 ve B7 arasında 8 modelden oluşmaktadır. Model oluşturulurken konvolüsyon katmanında üç argüman kullanılmıştır. İlk "weights" (ağırlıklar) parametresine "imagenet" değeri girilerek ImageNet'te ön eğitim yapılması sağlanmıştır. Havuzlama katmanında Global Average Pooling2D işlemi uygulanmıştır. Ortalama olarak pooling işlemi yapılmakta ve girdinin ortamsal çevirileri yerine ortamsal bilgiyi toplar. Bu yöntemde özellik haritalarının üstüne tam bağlı katmanların dâhil edilmesi yerine özellik katmanlarının ortalaması alınır ve oluşturulan vektör "softmax" katmanına bağlanır [20]. Bir sinir ağı öğrendikçe nöron ağırlıkları belirli özelliklere göre yararlanarak öğrenme gerçekleştirir. Komşu nöronlar da bu öğrenmelere güvenerek ezberle gidebilmektedir. Bu durum çok ilerlerse modelin aşırı öğrenmesine dönüşür ve model kırılabilir bir yapı kazanır. Bunu önlemek amacıyla "Dropout" fonksiyonu kullanılarak 20% bir olasılıkla nöronlar rasgele bir şekilde ağdan çıkarılmıştır. Böylece diğer nöronların devreye sokularak eksik nöronların yerine tahminleri yapmaları sağlanmıştır. Sinir ağı katmanında Dense önceki katmandaki tüm düğümleri mevcut katmana bağlar. Düzleştirme yoluna gider ve girişin hangi sınıfa ait olduğunu göstermektedir. Dense parametresi olarak 2 sınıfla çalışıldığı için "2" ve aktivasyon fonksiyonu olarak "softmax" girilmiştir. Modelin sınıflandırmaya uygun çıktı vermesi için "softmax" kullanılmıştır. KSA içinde olasılık kontrolü sırasında negatif değerler softmax sayesinde önlenir. "softmax" model vektörel olarak verilirken mutlak değerler üzerinden hareket eder.

Model giriş BT görüntülerinin etiketlerini benign ve malignant olarak belirlemek için sınıflandırma görevini gerçekleştirir. Modelin katman detayları ve katman parametreleri Tablo 1'de verilmiştir.

Tablo 1: Modelin katman detayları ve katman parametreleri

Katman No	Katman Tipi	Çıkış Boyutu	Eğitilebilir Parametre Sayısı
1	Conv2D	(32,256,256)	864
2	Conv2D	(16,256,256)	512
3	Conv2D	(96,256,256)	1536
4	Conv2D	(24,128,128)	2304
5	Conv2D	(144,128,128)	3456
6	Conv2D	(24,128,128)	3456
7	Conv2D	(40,64,64)	5760
8	Conv2D	(40,64,64)	9600
9	Conv2D	(80,32,32)	19200
10	Conv2D	(80,32,32)	38400
11	Conv2D	(112,32,32)	53760
12	Conv2D	(192,16,16)	129024
13	Conv2D	(320,16,16)	368640
14	Conv2D	(1280,16,16)	409600
15	Pooling2D	1280	0
16	Dense	2	2562

Önerilen modelde 14 evrişim katmanı bulunmaktadır. Şekil 2’de görüldüğü gibi her EffcientNetB0 katmanında bir evrişim katmanı ve onu takip eden BatchNormalization, Activation ve DepthwiseConv2D işlemleri ardışık biçimde bulunmaktadır. Batch_normalization işlemi yığın normalleştirilmesi yoluyla girdileri yeniden ölçeklendirip sinir ağlarının eğitimine hız ve kararlılık katmaktadır. Böylece ağ katmanları önceki katmanların öğrenmesini beklemeden eş zamanlı öğrenir.



Şekil 2: Önerilen model mimarisi (EfficientNetB0)

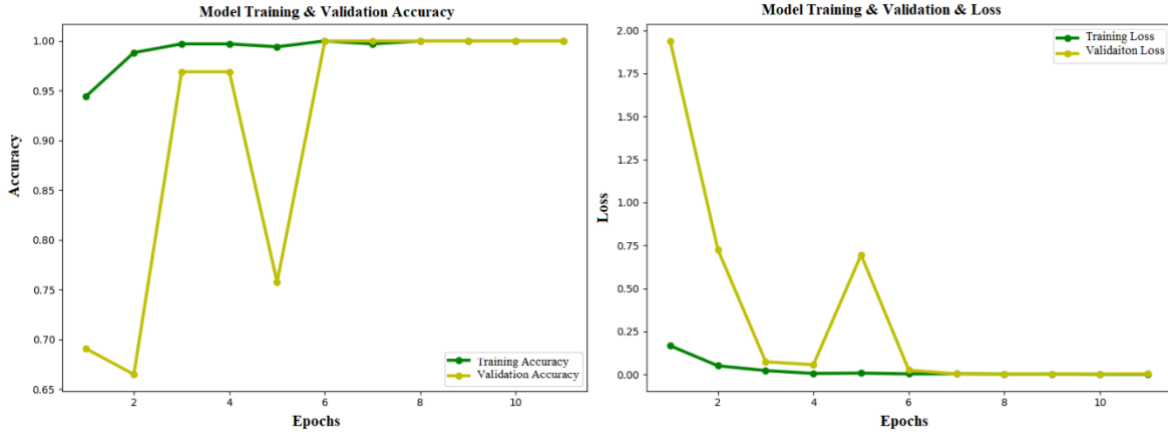
Model derleme sürecinde bazı parametreler kullanılarak eğitim ortamı kontrol edilmiştir. Bu parametrelerden biri olan “optimizer” , “Adam” değerini almıştır. Bu değer eğitim boyunca öğrenme oranının ayarlayan bir algoritmadır. İdeal öğrenme oranı (lr) değeri olarak Adam için çalışmada 0.0001 değeri verilmiştir. Model eğitiminde kayıp fonksiyonu olarak $loss='categorical_crossentropy'$ kullanılmış ve bu fonksiyon iki olasılık dağılımı arasındaki mesafeyi ölçmektedir. Ölçüm değeri metrik olarak accuracy (doğruluk) atanmıştır. “ModelCheckpoint” argümanı kullanılarak belli aralıklarla eğitimin model ağırlıkları kaydedilmiştir. $Verbose=1$ değeri ile anlık olarak güncellenen sonuçlar gösterilmiştir. Her yinelemede ezberi engellemek için ve eğitim verilerine daha iyi uymasını sağlamak için eğitim verisi güncellenmiştir. Bunun için de “EarlyStopping” argümanı kullanılmıştır. Çalışmada eğitim esnasından takip edilen değerlerde epochs adımları boyunca iyileşme olmadığı takdirde devreye öğrenme hızını küçülten bir katsayı olarak ReduceLROnPlateau fonksiyonu kullanılmıştır. Belirlenen katsayı $factor=0.3$ olarak girilmiştir.

2.3. Sınıf Aktivasyon Haritaları

Derin öğrenme yöntemlerinin kapalı-kutu yapısı nedeniyle güvenilirliğin düşmesinin önüne geçmek amacıyla, genellikle sınıf aktivasyon haritaları (Class Activation Maps - CAM) gibi tekniklerin kullanıldığı açıklanabilir modeller önemli bir araştırma konusu olmuştur. Çalışmada oluşturulan derin öğrenme modeli üzerinde Grad-CAM, Layer-CAM, Smoothgrad-CAM++ gibi bazı önemli sınıf aktivasyon teknikleri ile ısı haritaları elde edilmiştir. Grad-CAM Gradyan ağırlıklı CAM tekniğidir. Kaba bir yerelleştirme haritası oluşturmak için son katmandaki hedef (çalışmada tümör) gradyanları kullanarak önemli bölgelerde tahmin yürütür. En yüksek softmax olasılığına ait etiket seçilerek 2 boyutlu (2D) bir resim için gradyan hesabı 3D şeklinde sonuç verir. Bu haritalamada Global Average Pooling işlemi yapılır. CAM aksine GradCAM için yeniden eğitim gerekmez. Grad-CAM++ tekniği ikinci dereceden gradyanları kullanarak işlem yapmaktadır. XGrad-CAM tekniği aksiyom tabanlıdır. Aksiyomlar yöntem için gerekli düşünülen süreklilik, uygulamanın değişmezliği, hassasiyet ve koruma gibi değerlerdir. Grad-CAM ve türevlerinin hepsinde parametre olarak bir giriş modeli, bir hedef katman ve toplu boyutlandırma haricinde beklenen giriş tensörünün şekli bulunmaktadır. Çalışmada eğitilen model, model parametresine, modelin son katmanı olan top_conv hedef katmana eklenerek işlem yapılmıştır. Smoothgrad-CAM++ tekniğinde ise yukarıda bahsedilen parametrelere ek olarak yumuşatma için kullanılacak örnek sayısı "num_samples" parametresine çalışma için 4 değeri, gürültünün standart sapması std için çalışmada 0.3 değeri kullanılmıştır. LayerCAM kullanıma hazır herhangi bir CNN tabanlı modele uygulanabilir ve nesne lokalizasyonu ve semantik segmentasyon için fayda sağlayan farklı katmanlardan sınıf aktivasyon haritaları oluşturur.

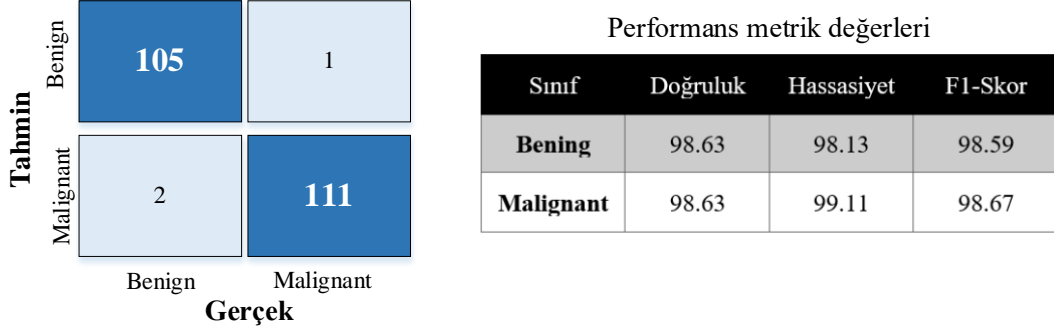
3. Deneysel Sonuçlar

Model eğitimi sonucu accuracy değeri 98.63% ve loss değeri 1.749% olarak tespit edilmiştir. Şekil 3'de görüldüğü gibi Epochs adımları ilerledikçe kayıp değerleri çok küçük kalmakta ve yüksek oranda tahmin doğruluğu sağlanmaktadır.



Şekil 3: Model eğitim ve tahmin doğruluğu, eğitim ve tahminde kayıp değişimi


Her bir görüntünün sınıfa aitliğinin bulunmasındaki doğruluğun ölçüldüğü karmaşık matrisleri Şekil 4'de görülmektedir. *Benign* sınıfı için 0, *malignant* sınıfı için 1 kullanılmıştır. Sonuçlara göre seçilen *benign* sınıfına ait 106 test verisinden 1 tanesi dışında, *malignant* sınıfına ait 113 test verisinden 2 tanesi dışında diğerlerinde doğru tahmin yapılmıştır. Doğruluk metriğinin %98.63 olarak ölçüldüğü test görüntülerde hassasiyet değerinin *malignant* sınıfı için %99.11 olarak yüksek olduğu görülmektedir.



Şekil 4: Model eğitimine ait karışıklık matrisi ve performans metrik değerleri

Görsel Sonuçlar ve Radyolog Yorumları

Test verileri üzerinde modelin odaklandığı bölgeleri tespit etmek için sınıf aktivasyon fonksiyonları kullanılmıştır. Sınıf aktivasyon fonksiyonlarından elde edilen görseller uzman radyolog tarafından yorumlanmıştır. Böylece modele açıklanabilir bir yapı kazandırılmıştır. Şekil 5’te Grad-CAM, Layer-CAM ve Smooth GRAD-CAM++ teknikleri ile elde edilen görüntüler verilmiştir.



Şekil 5: Grad-CAM, Layer-CAM ve Smooth GRAD-CAM++ teknikleri ile elde edilen görüntüler

Aktivasyon haritalarından görüleceği gibi modelin bazı görüntülerde modelin akciğer morfolojisine odaklandığı görülmektedir. Kanserli bölgedeki akciğer şekli tümörden dolayı bozulduğu için model normal olan akciğer üzerindeki odakları üzerinden karar vermiştir. Bazı görüntülerde doğrudan tümör olan akciğer bölgesine de odaklandığı görülebilmektedir.

Radyolog Yorumları:

- 1. Vakada sağ akciğer üst lobda primer akciğer kitle lezyonu, sol akciğerde birkaç adet milimetrik boyutlu metastatik (yayılım) pulmoner nodül mevcuttur. Model aktivasyon haritasında sağ akciğerdeki primer lezyona odaklanmıştır. Fakat kitlenin sol akciğere yayılımını gösteren daha küçük boyutlu metastatik lezyonlara odaklanmadığı görülmektedir.
- 2. Vakada sol akciğerde iyi huylu parankimal atelektazik bant olarak yorumladığımız iyi huylu lezyon dışında kanser bulgusu gösterecek başka bir lezyon izlenmemiştir. Fakat model herhangi bir bulgu olamayan normal akciğer dokusuna yanlış pozitif odaklanma göstermiştir. Bu görüntülerde modelin ayrıca normal kemik doku ve kalp dokusuna da odaklandığı izlenmiştir.

- 3. Vakada sol akciğer taban kesiminde büyük boyutlu bir kanser kitlesi mevcuttur. Sağ akciğer parankimi doğal izlenmiştir. Modelin normal akciğer parankimine daha fazla olmak üzere hem normal akciğer hem sol akciğerdeki kitleye odaklandığı izlenmiştir.
- 4. Vakada sağ akciğerde yaygın akciğer zarı ve bir kısım batın(karın) kesitlerini tutan kitle lezyonu izlenmiştir. Modelin tamamen başarılı şekilde doğrudan kitlelere odaklandığı izlenmiştir.

Sonuç olarak model en başarılı odaklanmayı 4. Vakada göstermiştir. Bunun nedeninin mevcut kitlenin daha büyük bir anatomik alanı tutmasından kaynaklı olduğu düşünülmektedir. Sonraki başarılı odaklanmanın 1. Vaka ve 3. odaklanma göstermiştir. Buradaki kitle lezyonu çok büyük boyutlu olmamakla birlikte model yine de lezyonu işaret etmektedir. İlk vakadaki küçük boyutlu lezyonlar işaretlenmemiştir. Model büyük boyutlu kitleleri tespit edebilmektedir. Kitle bulunan görüntülerde odaklanmanın olduğu yerin ayna hayali izdüşümü olan yerlerde hafif yanlış odaklanmalar mevcuttur. Bu yanlış görüntülerin azaltılması gerekmektedir.

Yazarların Katkısı

Bu makalenin yazılmasına tüm yazarlar eşit katkıda bulunmuştur.

Çıkar Çatışması

Yazarlar çıkar çatışması olmadığını belirtmektedir.

Referanslar

- [1] Witschi H. A short history of lung cancer. *Toxicol Sci.* 2001;64(1):4–6.
- [2] Kaya U, Yılmaz A, Dikmen Y, Beigelman-Aubry C, Dunet V, Brun AL, et al. Comparison of the automatic segmentation of multiple organs at risk in CT images of lung cancer between deep convolutional neural network-based and atlas-based techniques. *Diagn Interv Imaging* [Internet]. 2019;97(16):973–89. Available from: <https://doi.org/10.1080/0284186X.2018.1529421>
- [3] Espinoza JL, Dong LT. Artificial intelligence tools for refining lung cancer screening. *J Clin Med.* 2020;9(12):1–17.
- [4] Christie JR, Lang P, Zelko LM, Palma DA, Abdelrazek M, Mattonen SA. Artificial Intelligence in Lung Cancer: Bridging the Gap Between Computational Power and Clinical Decision-Making. *Can Assoc Radiol J.* 2021;72(1):86–97.
- [5] Radhika PR, Nair RAS, Veena G. A Comparative Study of Lung Cancer Detection using Machine Learning Algorithms. *Proc 2019 3rd IEEE Int Conf Electr Comput Commun Technol ICECCT 2019.* 2019;1–4.
- [6] Ait Skourt B, El Hassani A, Majda A. Lung CT image segmentation using deep neural networks. *Procedia Comput Sci* [Internet]. 2018;127:109–13. Available from: <https://doi.org/10.1016/j.procs.2018.01.104>
- [7]. Yokota K, Maeda S, Kim H, Tan JK, Ishikawa S, Tachibana R, et al. Automatic detection of GGO regions on CT images in LIDC dataset based on statistical features. *2014 Jt 7th Int Conf Soft Comput Intell Syst SCIS 2014 15th Int Symp Adv Intell Syst ISIS 2014.* 2014;1374–7.
- [8] Mhaske D, Rajeswari K, Tekade R. Deep learning algorithm for classification and prediction of lung cancer using CT scan images. *Proc - 2019 5th Int Conf Comput Commun Control Autom ICCUBEA 2019.* 2019;
- [9] Abdul W. An Automatic Lung Cancer Detection and Classification (ALCDC) System Using Convolutional Neural Network. *Proc - Int Conf Dev eSystems Eng DeSE.* 2020;2020-Decem:443–6.
- [10] Chen Y, Wang Y, Hu F, Feng L, Zhou T, Zheng C. Ldnnet: Towards robust classification of lung nodule and cancer using lung dense neural network. *IEEE Access.* 2021;9:50301–20.
- [11] Bharati S, Podder P, Paul PK. Lung cancer recognition and prediction according to random forest ensemble and RUSBoost algorithm using LIDC data. *Int J Hybrid Intell Syst.* 2019;15(2):91–100.
- [12] Chen L, Chen J, Hajimirsadeghi H, Mori G. Adapting grad-CAM for embedding networks. *Proc - 2020 IEEE Winter Conf Appl Comput Vision, WACV 2020.* 2020;2783–92.
- [13] Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *Proc IEEE Int Conf Comput Vis.* 2017;2017-Octob:618–26.
- [14] Panwar H, Gupta PK, Siddiqui MK, Morales-Menendez R, Bhardwaj P, Singh V. A deep learning and grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images. *Chaos, Solitons and Fractals* [Internet]. 2020;140:110190. Available from: <https://doi.org/10.1016/j.chaos.2020.110190>
- [15] Pradhan K, Chawla P. Medical Internet of things using machine learning algorithms for lung cancer detection. *J Manag*

- Anal. 2020;7(4):591–623.
- [16] Zakriya KJ, Christmas C, Wenz JF, Franckowiak S, Anderson R, Sieber FE. Preoperative Factors Associated with Postoperative Change. 2002;1628–32.
- [17] Fan BB, Yang H. Analysis of identifying COVID-19 with deep learning model. J Phys Conf Ser. 2020;1601(5).
- [18] alyasriy hamdalla, AL-Huseiny M. The IQ-OTH/NCCD lung cancer dataset. 2023;4.
- [19] Goodfellow, I., Bengio, Y., & Courville A. Deep learning. 2016.
- [20] Gong W, Chen H, Zhang Z, Zhang M, Gao H. A Data-Driven-Based Fault Diagnosis Approach for Electrical Power DC-DC Inverter by Using Modified Convolutional Neural Network with Global Average Pooling and 2-D Feature Image. IEEE Access. 2020;8:73677–97.