

Akciğer Kanseri Tespitinde Dönüşüm ve Evrişim Tabanlı Modeller ile Açıklanabilir Yapay Zeka Uygulaması

Explainable Artificial Intelligence Application for Lung Cancer Detection with Transformer and Convolution Based Models



Delal Şeker¹,



Mustafa Said Kartal²,



Abdulnasır Yıldız³, İlkay Öksüz⁴

¹Mühendislik Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye, delalkabak93@gmail.com

²Tip Fakültesi, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye, md.mustafasaidkartal@gmail.com

³Mühendislik Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye, abnayil@dicle.edu.tr

⁴Istanbul Technical University, İstanbul, Türkiye

Faculty Of Computer And Informatics Engineering, Department Of Computer Engineering
oksuzilkay@itu.edu.tr

Özetçe— Günümüzde dijital patoloji, tümörlerin teşhisi ve tahminleme konusunda önemli bir rol oynamaktadır. Derin Öğrenme (DÖ) yöntemlerinin geniş ölçekli uygulamalarla başa çıkma yeteneği göz önüne alındığında, bu tür modeller, histopatolojik görüntülerde doku sınıflandırma için cazip bir çözüm olarak kullanılmaktadır. Bu çalışma, histopatolojik görüntülerden akciğer kanserinin otomatik sınıflandırması için doğru ve yorumlanabilir bir makine öğrenimi tekniği oluşturmayı amaçlamaktadır. Mevcut yöntemde Evrişimsel Sinir Ağları (ESA), Vision Transformer (ViT) ve EfficientNet-B1 mimarisi karşılaştırılarak LIME (Local Interpretable Model-agnostic Explanations) açıklanabilirlik metoduyla patoloji görüntüleri üzerinde kanser tespit sistemi önerilmiştir. ViT ve EfficientNet-B1 mimarisinin evrişim tabanlı ESA mimarisine göre F1-skoru, hassasiyet ve duyarlılık oranının daha başarılı sonuçlar verdiği gözlemlenmiştir. En yüksek başarımların ViT mimarisi ile yaklaşılmış olup en ayrıntılı LIME sonuçlarına ise EfficientNet-B1 mimarisi ile ulaşılmıştır.

Anahtar Kelimeler — Evrişimsel Sinir Ağları, EfficientNet-B1, Vision Transformer, Histopatoloji, Açıklanabilir Yapay Zeka

Abstract— In today's context, digital pathology plays a significant role in the diagnosis and prediction of tumors. Given the capability of Deep Learning (DL) methods to handle large-scale applications, such models are being increasingly employed as an attractive solution for tissue classification in histopathological images. This study aims to establish an accurate and interpretable machine learning technique for the automatic classification of lung cancer from histopathological images. In the current approach, a cancer detection system on pathology images is proposed by comparing Convolutional Neural Networks (CNNs), Vision Transformer (ViT), and EfficientNet-B1 architectures, utilizing the Local Interpretable Model-agnostic Explanations (LIME) interpretability method. It has been observed that the ViT and EfficientNet-B1 architectures outperform the convolution-based CNN architecture in terms of F1-score, precision, and recall rates. The ViT architecture approaches the highest performance rate, while the most detailed LIME results are achieved with the EfficientNet-B1 architecture.

Keywords — Convolution Neural Network, EfficientNet-B1, Vision Transformer, Histopathology, Explainable Artificial Intelligence

GİRİŞ

Akciğer kanseri dünya genelinde geniş bir kesimi ilgilendiren sağlık sorunlarının başında gelir. Ölüm oranı yüksek ve kritik bir sağlık sorunudur. Akciğer kanseri hastalığına başlıca yakalanma sebebi sigara ve alkol tüketimidir. Bunun yanı sıra coğrafi bölgelere, yaş gruplarına, kalıtsal özelliklere ve diğer değişkenlere bağlı olarak farklılık gösterebilmektedir [1]. Kanser belirtileri arasında bitkinlik, mide bulantısı, kronik öksürük, nefes darlığı, kilo kaybı, kas ağrıları, kanama ve morluklar yer almaktadır. Fakat her kanser hastasında bu gibi durumlar görülmemektedir. Çoğu zaman akciğer kanser tanısı Pozitron Emisyon Tomografi (PET), Manyetik Rezonans (MR) veya Bilgisayarlı Tomografi (BT) ile görüntülenip ardından kesin tanı için patolojik teşhise ihtiyaç vardır [2]. Genel olarak, akciğer kanseri erkeklerde daha yaygın görülürken, kadımlar arasında da son yıllarda artış gözlemlenmektedir [3]. 2020 WHO raporlarına göre dünya genelinde akciğer kanseri vakaları 2.21 milyon iken ölü sayısı 1.8 milyonu aşmaktadır [4].

Sistemik ve standartlaştırılmış tanı yöntemlerinin eksikliği, erken evre kanserlerin (1. veya 2. evre) ve belirsiz tümörlerin teşhisini zorlaştırmaktadır. Bu durumda, klinisyenler genellikle klinik tanı için dokulardan girişimsel biyopsi yöntemiyle örnekler alma yoluna başvurmurlar. Patolojik doku örneklerinin histolojik veya hücresel seviyede nihai tümör türü ve evresi belirlenebilmektedir [5]. Gelişen teknoloji ve yapay zeka modelleri sonucu komplikasyona sebep olan girişimsel yöntemlerin seyreltilmesi amaçlanmaktadır [6].

Günümüzde bilgisayar tabanlı görüntü işleme teknikleri, patolojik görüntülerin analizini otomatikleştirmektedir. Bu sayede süreci hızlandırmakla birlikte yüksek teşhis oranları elde edilmektedir [7]. Bu teknikler arasında görüntü bölütlemesi, özellik çıkarma ve sınıflandırma gibi yöntemler bulunmaktadır. Gelişmiş bilgisayar algoritmaları ve yapay zeka mimarileri, patoloji uzmanlarının hastalıkları daha iyi tanımlamasına ve tedavi planlarını belirlemesine yardımcı olabilmektedir.

Bu çalışmada, akciğer histopatoloji görüntülerine baz model olarak Evrişimsel Sinir Ağları (ESA), dönüşüm tabanlı Vision

nimarileri uygulanmıştır. Derin Öğrenme (DÖ) modellerinin uygulanmasıyla elde edilen kestirim sonuçları karşılaştırılmıştır. Ardından tüm modellere ait sonuçlar çıkarılabilir yapay zeka yöntemi olan LIME (Local Interpretable Model-agnostic Explanations) ile ilişkilendirilmiştir. LIME uygulaması sonucu elde edilen görüntülerin ilgili bölgeleri çalışmada gösterilmiştir.

Mevcut Çalışmalar

Histopatolojik doku örneklerinin analizi ve sınıflandırılmasında farklı yaklaşımlar göze çarpmaktadır. Literatür incelendiğinde bu çalışmaların ağırlıklı olarak dönüşüm ve evrişim tabanlı olduğu gözlemlenmektedir. Aitazaz ve ekibi (2023), akciğer görüntülerini teşhis etmede ViT ve önceden eğitilmiş ESA mimarilerinin etkinliğini karşılaştırılmıştır. Deneyin sonuçları, ViT mimarisinin önceden eğitilmiş ESA mimarilerini performans bakımından aştığını göstermiştir. Ayrıca, daha fazla katmana sahip olan ViT-L32'nin ViT-B32'ye nazaran daha doğru sonuçlar ürettiği bulunmuştur [8]. Ali ve Ali (2021), geleneksel katmanlar, ayrılabilir evrişim katmanları ve kapsül içeren çok girişli bir hibrit model oluşturmuşlardır. Bu modeli akciğer kanserini sınıflandırmak için kullanmışlardır. Ön işleme aşamasında, gama düzeltme, renk dengeleme, görüntü keskinleştirme ve çok ölçekli birleştirme uygulanmıştır. Önerilen model iki giriş alır: i) standart evrişim katmanları aracılığıyla birinci giriş bloğundan ham görüntüler ve ii) ayrılabilir evrişim katmanları kullanılarak ikinci giriş bloğundan işlenmiş görüntülerin her ikisi de sınıflandırma için bir kapsül ağına bağlıdır. Deneysel analiz, önerilen modelin tüm sınıflarda dikkate değer bir başarı elde ettiğini ve akciğer kanseri için genel doğruluğun %99.58 olduğunu göstermişlerdir [9]. Kumar ve ark. (2022), akciğer histopatoloji görüntülerini sınıflandırmak için elle çıkarılan (hand-crafted) özelliklerin performansını derin özelliklerle karşılaştırmışlardır. Elde edilen özellikler dört makine öğrenimi algoritmasına uygulanmıştır: Gradient Boosting (GB), Çok Katmanlı Algılayıcı (ÇKA), Rastgele Orman (RO) ve Radyal Fonksiyon tabanlı Destek Vektör Makinası (DVM-RBF). Analiz sonrasında, derin özelliklere sahip sınıflandırıcıların manuel özellikleri aştığını gözlemlenmişlerdir [10]. Ibrahim ve Alaattin (2022), özellik çıkarmak için EfficientNet-B7 kullanarak akciğer kanseri için çoklu sınıflandırma yapmak amacıyla Modifiye Edilmiş Sinir Ağları (MNNs) kullanarak DÖ tabanlı bir sistem önermişlerdir. Sonuçlara göre, bu sistem ile %99.5 doğruluk elde etmişlerdir [11]. Fan vd. (2021), akciğer kategorizasyonu için softmax ve DVM tabanlı bir transfer öğrenme mimarisi önermişlerdir. Sınıflandırma doğruluğunu artırmak için softmax sınıflandırıcısının tam bağlı katmanı, DVM sınıflandırıcısına bağlanmıştır. Önerilen modelin LC25000 veri kümesi için %99.4 doğruluğa sahip olduğunu göstermişlerdir [12]. Mehmood ve ekibi (2022), akciğer kanseri histopatolojik görüntülerinin otomatik olarak teşhisi için etkili bir transfer öğrenme stratejisi önermişlerdir. Bu yaklaşımda, hesaplama maliyetini azaltmak ve doğruluğu artırmak amacıyla kontrast artırma yöntemi tüm görüntülere değil, sadece performansı düşük olan sınıfa uygulanmıştır (%89'dan %98.4'e kadar artış). Talukder ve ark. (2022), akciğer kanserini tespit

için MobileNet kullanılıp sınıflandırma amacıyla birleşti yumuşak oylama sınıflandırıcısı kullanılmışlardır. Araştırma bulgularına göre, önerilen teknik ile akciğer kanserini sınıflandırmada %99.3 doğruluk sonucuna varılmıştır [13]. Mangal vd. (2020), akciğer kanserini tanımlamak amacıyla geliştirilmiş sığ bir ESA tabanlı teknik kullanmış ve akciğer kanseri için %97, doğruluk elde edilmiştir [14]. Adu ve ark. (2021), akciğer kanserini otomatik olarak tespit etmek ve sınıflandırmak için kapsül tabanlı bir metodoloji önermiştir. Bu çalışmada, kodlayıcı tabanlı benzersiz bir özellik birleştirme yaklaşımı ve özellik vektörünü bastırma için yeni bir yata sıkıştırma fonksiyonu geliştirilmiştir. Önerilen strateji ile %99.23 doğruluk oranı yakalanmıştır [15]. Hage Chehad ve ark. (2022), akciğer histopatolojik görüntülerin çoklu sınıflandırılması için özellik mühendisliğine dayalı yeni bir makine öğrenimi modeli önermiştir. Bu yöntem, birinc dereceden istatistikler, GLCM ve Hu değişmez momentle kullanılarak 37 manuel çıkarılmış özellik hesaplamışlardır. Akabinde bunları sınıflandırma işlemi için XGBoost sınıflandırıcısına uygulanmıştır. İlgili modelin LC25000 veri kümesi üzerinden test başarımının doğruluk performansı %99 olarak tespit edilmiştir.

MATERYAL VE METOT

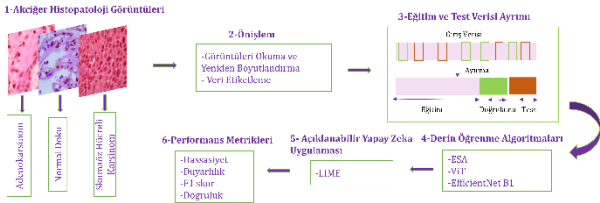
A. Veri seti

Bu çalışmada, Kaggle platformundan LC25000 adlı veri seti kullanılmıştır. İlgili veri, Florida'da bulunan Jame Hastanesinde görev yapan Andrew Borkowski ve ekibi tarafından oluşturulmuştur. Veri seti, akciğer ve kolon kanser histopatolojik görüntülerini içermektedir. Akciğer kanseri ü farklı sınıftan oluşmaktadır. Orijinal görüntü boyutları (1024,768) olup görüntüler (768,768) şeklinde yeniden boyutlandırılmıştır. Veri seti toplamda 750 adet akciğer kanser 500 adet kolon histopatolojik görüntü barındırmaktadır. Veri artırma metodu sayesinde (sağ ve sol rotasyonlar- yatay ve dikey döndürmeler) her sınıftan 5000 adet olmak üzere toplamda 25000 adet görüntü elde edilmiştir. Önerilen çalışmada 15000 adet akciğer histopatolojik görüntüde faydalanılmıştır. Çalışmada kullanılan açık erişim veri setinde akciğer ve kolon kanseri görüntüleri ayrı ayrı sınıflandırılmıştır. Fakat önerilen metod sadece akciğer verisine uygulanmıştır. Verinin kapladığı alan bilgisi ve LC25000 adı kullanılması sebebi ile 2 sınıflı kolon görüntülerini de barındırdığı bilinmemektedir. Tüm veri setinin kapladığı alan 1.85 GB büyüklüğündedir [16]. Akciğer kanseri için akciğer normal dokusu (ND), akciğer adenokarsinomu (ADK) ve akciğer skuamöz hücreli karsinom (SHK) olarak adlandırılan sınıflarda çalışmada irdelenmiştir. Akciğer adenokarsinomu bronşlarda görülen ikinci en yaygın kanser türüdür. Akciğerdeki bu hücrelerin ortaya çıkar. Skuamöz hücreli karsinom, tıpkı adenokarsinom gibi akciğerin alveol ve bronş epitelinde kaynaklanan habis tümörlerdir ve öncül lezyonlardan gelişirler. Patoloji rutininde girişimsel karsinom diyebilmek için hücreye düzeyde anormal görünümün yanında bu hücrelerin yapıya olarak da anormal davranışını saptamak gerekmektedir. Hücresel atipi daha çok hücrenin çekirdek özelliklerini

eğerlendirilmektedir [17]. Son olarak kontrol grubu olan ening hücreler ise normal doku olup vücudun diğer ölgelerine yayılmamaktadır.

1. Metot

İlgili görüntüler (128,128,3) şeklinde yeniden boyutlandırılmış, EfficientNet-B1 mimarisi hariç, ESA ve ViT mimarisindeki [0-55] piksel değerleri normalize edilerek [0-1] arasına indirgenmiştir. Toplam görüntülerin %80'i eğitim, %20'si test kümesine ayrılmıştır. Geri kalan eğitim kümesinin %20'si ise öğretim kümesini oluşturmaktadır. Her sınıftan 5000 örnek alınarak eğitim-test kümeleri dengeli oluşturulmuştur. Bu bağlamda üç farklı DÖ modeli kullanılmıştır. Model sonrası üşis edilen görüntülere açıklanabilir bir yöntem uygulanıp sonuçlar karşılaştırılmıştır. Çalışmada izlenen metot Şekil 1.'de özetlenmiştir.



Şekil 1. Mevcut çalışmada takip edilen metodoloji

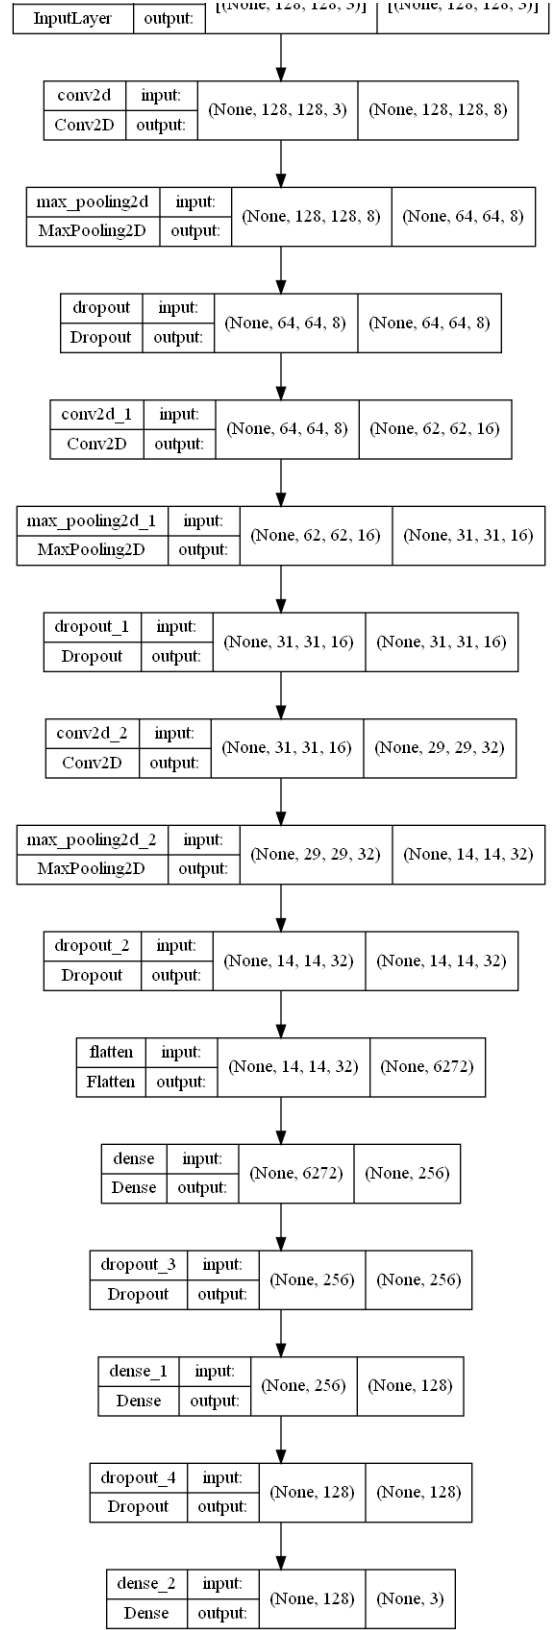
-Derin Öğrenme Modelleri

Evrişimsel Sinir Ağları (ESA):

ESA, özellik çıkarımı ve sınıflandırma işlemlerini eş zamanlı olarak gerçekleştiren bir DÖ algoritmasıdır. Bu yöntem, ham verilerden özelliklerin otomatik olarak çıkarılması için evrişim şamaları, aktivasyon fonksiyonları ve havuzlama katmanlarını kullanır. Evrişim işleminin özü, bir veya daha fazla filtre uygulanarak gerçekleştirilen bir matematiksel operasyona dayanmaktadır. Filtrelerin görüntü üzerinde seçilen piksel sayısı adımları ile kaydırılması sonucu özellik haritaları çıkarılır. Filtreleme adımına ait bağıntı Denklem (1)'de verilmiştir. 'b' bias (yanlılık) değerini, 'x' yerel bölgeyi, 'y' ise özellik haritasını temsil etmektedir [18].

$$y_j = \sum(x_i * k_j + b_j) \quad (1)$$

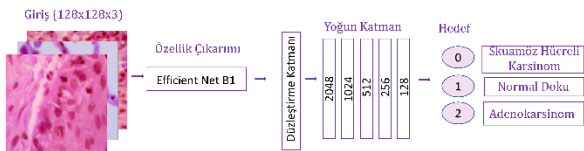
Önerilen ESA mimari yapısı Şekil 2'de gösterildiği gibidir. Bu çalışmada önerilen 3 katmanlı ESA modelinde katmanlardaki sinir hücresi sayısı sırası ile (8,16,32) şeklindedir. Her katmandaki kernel boyutu (3,3) olarak belirlenmiştir. Tüm evrişim işlemleri ardına (2,2) maksimum havuzlama uygulanmıştır. Mimariye (256,128) sinir hücresi sayılarında öğretim katmanı eklenmiştir. Hiper parametreler açısından batch boyutu 32, seyreltme oranı 0.3, öğrenme oranı 0.001, optimizasyon metodu olarak 'Adam', kayıp fonksiyonu olarak 'categorical_crossentropy', aktivasyon fonksiyonu olarak 'softmax' ve son olarak eğitim boyunca epok sayısı 50 seçilmiştir.



Şekil 2. Önerilen ESA mimarisi yapısı

EfficientNet-B1:

Google araştırma ekibinden Tan ve Le (2019), ConvNet istemlerinin ölçeklendirme yöntemlerini inceleyerek temel yapıyı oluşturmuşlardır [19]. Araştırmacılar, ConvNet'e daha fazla katman ekleyerek onları daha geniş ve derin hale getirip yüksek çözünürlüklerle uğraşmak oldukça zahmetli olabileceği için saniye başına kayan nokta işlemi (FLOPS) kullanıp temel bir ConvNet oluşturmak adına EfficientNet modeli kullanmışlardır. Bu mimari EfficientNet-B0 olarak adlandırılmıştır. Bu aşamadan sonra, EfficientNet-B1, EfficientNet-B0'ı ölçeklendirerek oluşturulmuştur. Ölçekleme seviyeni daha sonra EfficientNet-B7'ye uygulamışlardır. ImageNet veri kümesi üzerinde EfficientNet-B7 modelini kullanarak üst düzey doğruluk elde etmişlerdir. EfficientNet, diğer birçok derin öğrenme mimarisinden farklı olarak, ağırlık paylaşımı, genişliği ve çözünürlüğünü dengelemektedir. Bu dengeleme, daha iyi performans sağlamak için optimize edilmiştir. EfficientNet mimarisi daha sonra nesne tespiti için farklı çözünürlüklerde kaynaştırılmış özellikler kullanan EfficientNet (B0,B1,B2,B3,B4,B5,B6,B7) ailesini oluşturmak için kullanılmıştır [20]. Bu nedenle ilgili çalışmada, analiz edilen görüntülerin boyutu ve eğitim kolaylığı göz önünde bulundurularak EfficientNet-B1 ağ mimarisi tercih edilmiştir. İriş görüntüleri (128,128,3) için normalizasyon işlemi uygulanmayıp görüntülerin orijinal piksel değerleri ile giriş nöronları oluşturulmuştur. Mevcut çalışmada transfer öğrenme tabanlı EfficientNet-B1 derin öğrenme mimarisinin özellik çıkarıcı olarak kullanılıp dense (yoğun) katmanı ile geliştirilerek yapılan sınıf tahmini Şekil 3.'de gösterilmiştir. EfficientNet-B1 mimarisindeki katmanlar dondurularak ImageNet ağırlıklarının kullanımı ile önerilen görüntü sınıflandırma problemi, önceden eğitilmiş bir derin öğrenme modelinin özelliklerinin alınıp, yeni veri kümesindeki örnekler için sınıflandırma yapılmasını sağlar. Böylelikle büyük miktarda veriye ihtiyaç duymadan etkili bir şekilde yeni bir çevre için modelin uyarlanması gerçekleştirilir. İlgili mimariye tavuzlama olarak 'average pooling' seçilmiştir. Tam bağlantılı katmandaki sinir hücresi sayıları (2048, 1024, 512, 256, 128) şeklindedir. Bunun dışındaki hiper parametreler önerilen ESA nodeli ile benzerlik göstermektedir.



Şekil 3. EfficientNet-B1 derin öğrenme mimarisinin akciğer patolojik görüntü tahminlenmesinde kullanımı

Vision Transformer (ViT):


Dehghani vd. (2015), DÖ mimarilerinin kodlayıcı ve çözücü bloklarından oluşan karmaşık evrişimli modellerin dikkat mekanizmaları ile entegre olmasını sağlamışlardır. Böylece derinlemeli ve evrişimsel blokları tamamen ortadan kaldırmayı hedeflemişlerdir [21]. Bu çalışmaya dayanarak Dosovitskiy ve LeDehghani (2021), geleneksel Transformer modelinin görüntü

[22]. ViT, girdi olarak bir görüntüyü alıp önceden belirlenmiş belirli bir boyut ve piksel çözünürlüğüne sahip görüntüleri küçük yamalara böler. Daha sonra, bu görüntü yamalarını dikkat vektörlerine dönüştürür ve bir dizi dikkat katmanı üzerinden işler. ViT modelinin mimari yapısı Şekil 4.'de gösterilmiştir. Görüntüyü vektöre dönüştüren bağlantı Denklem (2)'de verilmiştir. Bu denklemde her bir görüntü için elde edilen terimler şu şekildedir: n yama sayısı, h yükseklik, w genişlik ve p piksel netliği vermektedir. Ardından görüntü yamaları $p^2 \times h \times w$ boyutunda vektörlere çevrilir.

$$n = (hw)/p^2 \quad (2)$$

Modelde (128,128,3) olan girdi görüntüleri (72,72,3) şeklinde yeniden boyutlandırılmıştır. Daha sonra her bir kenar 6 adet yamaya bölünmüştür. Böylelikle bir görüntüden toplam (6x6) 36 adet yama elde edilmiştir. Modele ait diğer hiper parametreler şu şekildedir: Kayıp fonksiyonu seyrek kategori ağırlık azalması 0.0001, projeksiyon boyutu 64, dönüşüm birimindeki projeksiyon boyutu 2, dönüşüm katmanının boyutu 8, son sınıflandırıcı olan çok katmanlı algılayıcının sinir hücresi sayıları (2018,1024) olarak belirlenmiştir.

Önerilen ViT mimarisinde büyük veri gereksiniminden dolayı eğitim kümesinde veri artırımı yoluna gidilmiştir. Mimarini iç yapısı gereği ilgili değişimler belirli oranda görüntülerin eksenine göre simetrisinin alınması, 0.02 faktörü ile döndürülmesi ve hem yatay hem düşeyde 0.2 faktörü ile yakınlaştırma şeklindedir. Bu işlemin amacı olası test görüntülerine karşı sistemi gürbüz bir şekilde eğitmeyi amaçlamaktadır.



Şekil 4. Çalışmada kullanılan ViT mimarisine ait genel iç yapısı [22].

2-Performans Metrikleri

Makine öğrenimi ile ilgili performans metrikleri, hassasiyet, geri çağırma, F1 skoru ve doğruluk değerleri dahil olmak üzere ölçülecektir. Kesinlik, doğru pozitiflerin (DP) doğru pozitif ve yanlış pozitifler (YP) toplamına oranı olarak hesaplanır. Yani, doğru pozitiflerin toplam pozitif tahminlere oranıdır. Duyarlılık, doğru pozitiflerin toplam doğru pozitifler ve yanlış negatifler (YN) toplamına oranı olarak hesaplanır. Yani, doğru pozitiflerin toplam pozitif gerçekler ile oranıdır. F1 skoru kesinlik ve duyarlılığın harmonik ortalamasıdır. Dengesi sınıflandırma problemlerinde sıklıkla tercih edilir. Doğruluk bir model tarafından yapılan tahminlerin genel doğruluğunu ölçer. Doğruluk, doğru tahminlerin (DN, YP) toplam tahminlere oranı olarak hesaplanır. Performans metrikleri hesaplamasının özeti Tablo 1'de bulunmaktadır.

Tablo 1. Performans metrikleri matematiksel hesabı

Kesinlik	Duyarlılık
DP	DP
DP + YP	DP + YN
F1-skor	Doğruluk
$\frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$	$\frac{\text{DP} + \text{DN}}{\text{DP} + \text{YP} + \text{YN} + \text{DN}}$

-Açıklanabilir Yapay Zeka Metodu:

IME (Local Interpretable Model-agnostic Explanations): Ö modelleri, genellikle karmaşık yapısı ve yüksek boyutlu eriler üzerindeki etkin performansı dikkat çekmektedir. İlgili modeller literatür çalışmalarında ‘kara kutu’ modeller olarak adlandırılmaktadır [23]. Bu terim, DÖ modellerinin iç işleyişi ve karar süreçlerinin anlaşılmasının zorluğunu ifade eder. Bu durum kritik uygulamalarda DÖ kullanımını ısıtlamaktadır. Tıbbi teşhis gibi kritik disiplinlerde makine öğrenimi kullanımında tahminlere tamamen güvenilmez, çünkü sonuçlar yanıltıcı olabilir. Bireysel tahminlere güvenmekten aşka, modelin saha koşullarında kullanılmadan önce bütün olarak değerlendirilmesi de gerekmektedir. Bu kararı vermek için, kullanıcıların modelin gerçek dünya verilerinde iyi performans göstereceğine ve ilgi çeken ölçütler doğrultusunda değerlendirileceğine güvenmeleri gerekmektedir. Bu sebeple DÖ algoritmalarının iç işleyişini anlamak ve şeffaf hale getirmek amacıyla açıklanabilir modeller kullanılmaktadır. Çalışmada eğitim ve test işlemi sonrasında açıklanabilir modellerden biri olan LIME metodu kullanılmıştır. LIME metodunda amaç seçilen örnekleme DÖ metodunda alınan giriş ve tahminlerin neden yaptığını anlamak ve bu tahminlere yakını eni tahmin bölgeleri belirlemektir. Yeni ağırlıklar elde edilen tahminlere göre ağırlıklandırılmaktadır. Görüntüler tahmin için (1,128,128,3) olarak yeniden boyutlandırılmıştır. Test örneğinden doğru olarak sınıflandırılan rastgele seçilmiş görüntü örnekleri ile modelin görüntü üzerinden özellik çıkardığı ilgili bölgeler kestirilmeye çalışılmıştır. LIME metodu kararlarını belirli bir örnek veya örnek kümesi üzerinde tanımlandırır. Model agnostik bir yaklaşım benimseyip herhangi bir makine öğrenmesi modeli ile uyumlu çalışır. Bu aydede temel bir açıklayıcı yapay zeka modeli olarak sıklıkla kullanılmaktadır [24].

$$\text{çıklama}(x) = \underset{g \in G}{\text{argmin}} L(f, g, \pi_x) + \Omega(g) \quad (3)$$

Denklem (3)’de x açıklanmak istenen görüntü, g vekil model, f orijinal model, π_x ise x görüntüsüne yakınlık ölççeği, L kayıp fonksiyonu minimum yapan fonksiyon ve $\Omega(g)$ vekil modelin özellik miktarını az sayıda tutabilmek için kullanılan bir düzenleyicidir.

BULGULAR VE TARTIŞMA


Çalışmada kullanılan veri seti ve mevcut yöntem, patolojik görüntülerin işlenmesinde ve yorumlanmasında literatüre katkı sağlamaktadır. 50 epok boyunca alınan eğitim validasyon

ait karmaşıklık matrisleri Şekil 5.’de verilmiştir. Karmaşık matrislerinden çıkarılan metrikler ise Tablo 2.’de bir arad hesaplanmıştır. ViT mimarisinin evrişim tabanlı ESA v EfficientNet-B1 mimarisine göre daha başarılı sonuçlar verdiği gözlemlenmiştir. ESA mimarisi %87.93, EfficientNet-B1 mimarisi %96.97 ve ViT mimarisi %98.40 doğruluk değerlerine ulaşmıştır. Derin mimariler sonucu farklı doküman örneklerinden çıkarılan özelliklere ait doku konumları LIME metodu ile belirlenerek Şekil 6.’da gösterilmiştir.

Önerilen çalışmanın bulgularına göre, ViT mimarisi doğruluk hassasiyet ve duyarlılık gibi performans metrikleri açısından incelendiğinde akciğer kanseri özelliği taşıyan histopatoloji dokuları sağlıklı görüntülerden ayırma amacıyla EfficientNet-B1 ve ESA mimarisine kıyasla daha az parametre sayısı ile daha etkili bir sonuç ulaşılmıştır. Evrişim tabanlı ESA ve transfe öğrenmeye dayalı EfficientNet-B1 mimarileri dikkat mekanizmasına dayalı dönüşüm tabanlı ViT mimarisini performans olarak gerisinde kalmıştır. Önerilen evrişim tabanlı mimariler arasında EfficientNet-B1 mimarisi patolojik görüntü sınıflandırma uygulamalarında daha başarılı performans sergilemiştir. Ek olarak EfficientNet-B1 mimarisi transfe öğrenme ile kullanılırken ESA mimarisi rastgele parametreler başlatılarak eğitilmiştir. Her iki mimari de evrişim tabanlı olmasına rağmen bu durum ESA mimarisi için dezavantajlı bir durum olarak kabul edilebilir. Önceden öğrenilmiş ağırlıkları yeni veri setlerindeki kullanımına ait yüksek başarımlar transfe öğrenmenin getirdiği en önemli kazançlardan biridir [25]. Ayrıca derin katmanlı EfficientNet-B1 modelinin LIME gibi model agnostik yaklaşımlarda görüntüdeki detayları çok sayıda kümelemesi patolojik görüntü uygulamalarında önem taşıdığı göstermektedir ancak ilgili mimarinin efektif kullanımı için tür slayt görüntülerden faydalanmak daha doğru bir yaklaşım olacaktır. İlgilenilen kanserli kısımlar ve önerilen derin öğrenme mimarileri arasındaki ilişki açısından şu şekilde bir yorumdan bahsedilebilir: i) ESA mimarisi akciğer kanserine ait ilgili yerlerden özellik çıkarırken bu bölgeyi daha geniş tuttuğu ilgisiz yerlerden de görüntü toplamıştır. ii) EfficientNet-B1 algoritmasında kümelene alanlar çok sayıdadır. Bu bağlamda tüm slaytlardan yararlanmak daha doğru olacaktır. İlgili görseller yama görüntülerini temsil etmektedir. iii) ViT mimarisinde ise hem sınıflandırma başarımı en yüksek olurken hem de en anlamlı bölgelerden özellik çıkarılmıştır. Sonuç olarak ViT akciğer kanserine ilişkin patolojik kesitleri analizinde en doğru ve anlamlı sonuçlar üretmiştir. Çalışmada LIME açıklanabilirlik yöntemi kullanılarak ViT, ESA v EfficientNet-B1 mimarilerinin eğitildiği görüntülerde öğrenile bölgelerin belirgin bir şekilde işaretlenmesi, araştırmaya önemli bir katkı sağlamıştır. Bu yaklaşım, DÖ mimarilerini içsel öğrenme mekanizmalarını daha anlaşılır ve yorumlanabilir hale getirerek modelin hangi özellikleri ve bölgeleri vurgulayarak öğrendiğini açıklığa kavuşturmuştur. Görüntü üzerinde işaretlenen kümeler ilgili bölgeleri teşhis etmek için kullanılmıştır. Bu bağlamda öğrenilen bölgelerin vurgulanması modelin kararlarını ve öğrenme süreçlerini daha şeffaf bir şekilde anlaşılmasına yardımcı olarak önerilen çalışmanın genel etkisini arttırmaktadır. Bu çalışmada kullanılan

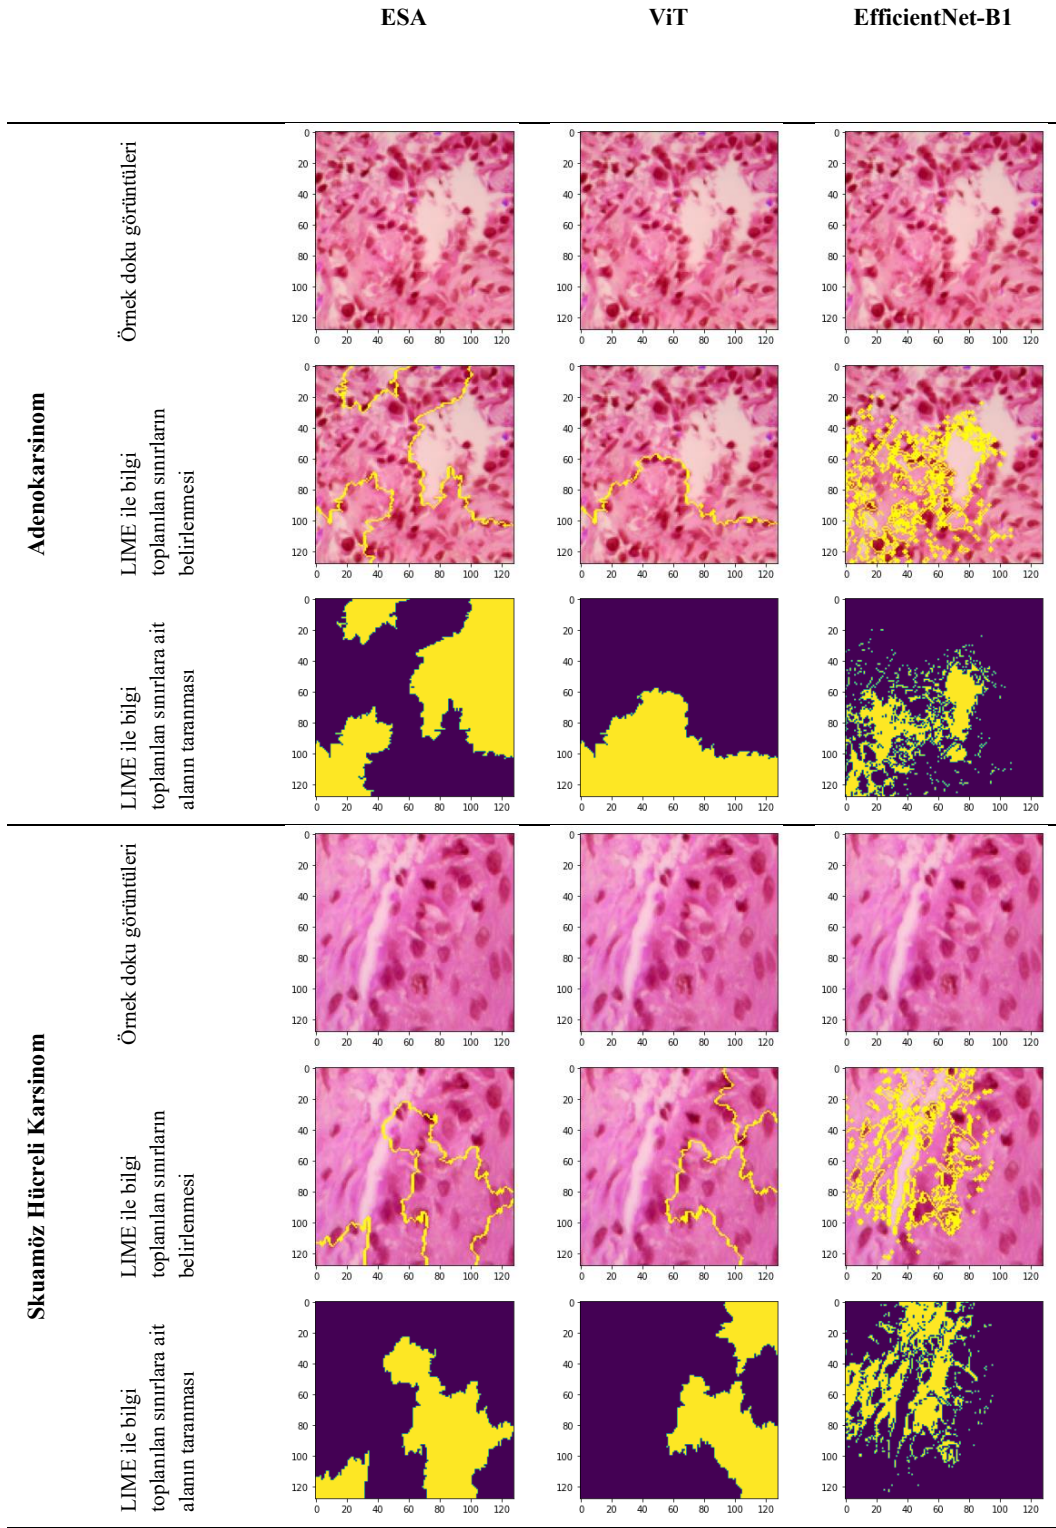
Boyutları için de denenmiş olup benzer sonuçlar vermiştir. Bu bağlamda GPU ve zaman kısıtından ötürü çalışmada küçük boyutlu görüntüler tercih edilmiştir. Çalışmada önerilen 3 katmanlı ESA modelinde seçilen eğitim parametrelerinin belirlenmesinde hiper-parametre optimizasyonu yapılmamıştır. Ayrıca tek bir açıklanabilir metot kullanıldığından bu uygulamaları destekleyecek farklı açıklanabilir metotlarının ortaya konmaması çalışmanın eksik görülen noktalarından bazılarıdır. Gelecek çalışmalarda histopatolojik görüntülerdeki kanser teşhisini geliştirmek amacıyla farklı DÖ modellerinin geliştirilmesi ve birden fazla açıklana bilirlik yöntemlerinin karşılaştırmalı analizinin yapılması hedeflenmektedir. Seçilen yöntemin hüresel ve dokusal bakımdan uzmanlık gerektiren görüntüler olması sebebiyle ileride yapılacak histopatolojik görüntü analizlerinin uzman bir patolog eşliğinde sonuçları yorumlaması çalışmaya katkı sunacaktır.

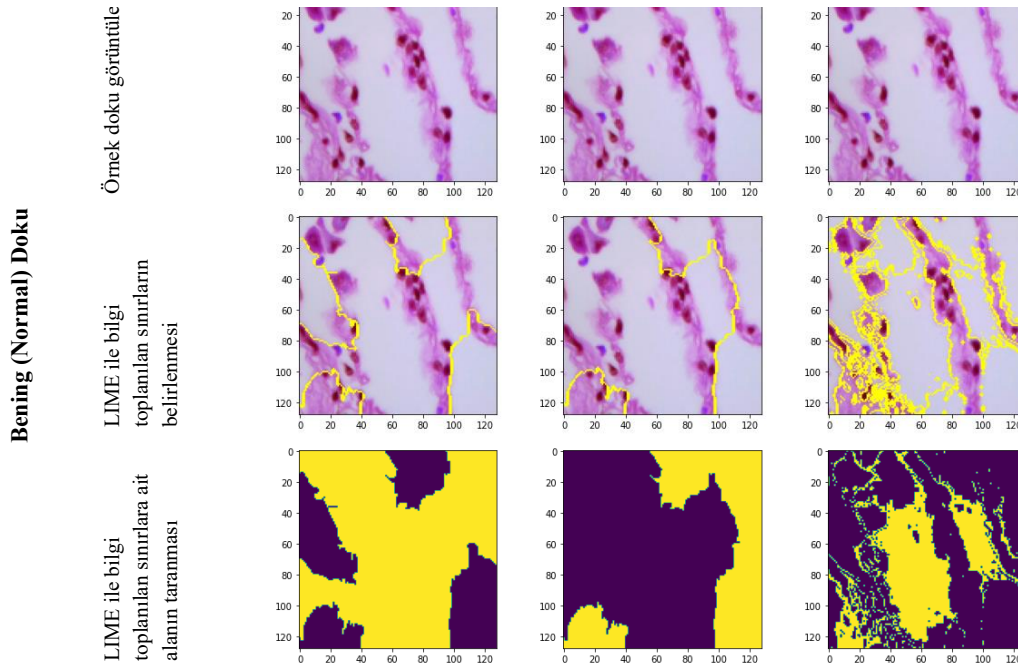
Mevcut çalışmanın yenilikçi yanları *Mevcut Çalışmalar* başlığı altında verilen literatür özeti ile kıyaslandığında şu şekilde sıralanabilir: **Çoklu Model Karşılaştırması:** ESA, ViT ve EfficientNet-B1 mimarileri karşılaştırılarak kapsamlı bir analiz yapılmıştır. Farklı derin öğrenme mimarilerini aynı veri kümesi üzerinde sistematik olarak karşılaştıran çalışmalar sınırlıdır. Bu çalışma, farklı modellerin performansını aynı veri seti ve aynı metrikler kullanarak doğrudan karşılaştırmaktadır. **Açıklanabilirlik Metodolojisi:** LIME metodunu kullanarak modellerin çıktılarının açıklanabilirliği değerlendirilmiştir. Literatürde açıklanabilirlik metotları genellikle sınırlı kullanılmıştır. Bu çalışmada, LIME ile modelin karar verme süreçlerinin görselleştirilmesi, modelin güvenilirliğini ve klinik uygulamadaki kullanım potansiyelini artırmaktadır. **Yüksek Doğruluk Oranları:** ViT mimarisinin %98.40 doğruluk oranına ulaşması ve EfficientNet-B1'in %96.97 doğruluk oranı ile yakın sonuçlar vermesine bulgular kısmında yer verilmiştir. Literatürdeki diğer çalışmalarla karşılaştırıldığında, önerilen yöntemlerin daha yüksek doğruluk oranlarına ulaşması, çalışmanın başarısını göstermektedir. **Detaylı Performans Değerlendirmesi:** Performans değerlendirmesinin sadece doğruluk oranıyla sınırlı kalmaması, diğer önemli metriklerin de kapsamlı bir şekilde analiz edilmesi, çalışmanın derinliğini ve geçerliliğini artırmaktadır. **Farklı Mimari Yapıların Kullanımı:** Literatürdeki çalışmaların çoğu ya sadece ESA ya da tek bir model mimarisi üzerine odaklanmıştır. Bu çalışmanın farklı mimarileri bir araya getirmesi ve karşılaştırması yenilikçi bir yaklaşım sunmaktadır. **Açıklanabilir makine öğrenmesi ile ayrıntılı ve şeffaf sonuçlar:** Literatürde LIME metodunun kullanımı yaygın değildir ve bu metodun özellikle EfficientNet-B1 ve ViT ile entegrasyonu, model çıktılarının daha iyi anlaşılmasını ve yorumlanmasını sağlamaktadır.



Şekil 5. ESA, ViT ve EfficientNet-B1 derin öğrenme mimarilerine ilişkin eğitim/validasyon kümelerine ait epoklar boyunca doğruluk-kayıp değerleri ile test kümesi karmaşıklık matrisleri

Tablo 2. Önerilen derin öğrenme mimarileri sonucu elde edilen performans metrikleri					
Derin Öğrenme Mimarisi	Sınıflar	Kesinlik	Duyarlılık	f1 skor	Genel Doğruluk
ESA	ADK	0.99	0.64	0.78	0.8793
	SHK	0.74	1.00	0.85	
	ND	0.99	1.00	1.00	
ViT	ADK	0.97	0.99	0.98	0.9840
	SHK	0.99	0.97	0.98	
	ND	1.00	1.00	1.00	
EfficientNet-B1	ADK	1.00	0.92	0.96	0.9697
	SHK	0.92	1.00	0.96	
	ND	1.00	0.99	1.00	





ekil 6. Adenokarsinom, skuamöz hücreli karsinom ve normal doku örnek görüntülerine ilişkin uygulanan derin mimariler sonucu LIME açıklanabilir yapay zek metoduna ait gösterimler

EŞEKKÜR

azarlar ilgili çalışmada Dicle Üniversitesi Bilimsel Araştırma rojeleri Koordinatörlüğü'nün (DÜBAP), sağladıkları finansal destek için (Proje No: MÜHENDİSLİK.17.019) teşekkürlerini unmaktadır. Ayrıca Acıbadem Maslak Hastanesi Mehmet Ali ydınlar Üniversitesinde patolog olarak görev yapan Cavit erem Kayhan'a sonuçların yorumlanmasındaki değerli atkıları için teşekkürlerimizi sunarız.

AYNAKLAR

- [1] M. B. Schabath and M. L. Cote, "Cancer progress and priorities: Lung cancer," *Cancer Epidemiol. Biomarkers Prev.*, vol. 28, no. 10, pp. 1563–1579, 2019, doi: 10.1158/1055-9965.EPI-19-0221.
- [2] M. C. Staff, "Cancer." Accessed: May 06, 2024. [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/cancer/symptoms-causes/syc-20370588>
- [3] L. L. Zullig *et al.*, "Cancer incidence among patients of the U.S. veterans affairs health care system: 2010 update," *Mil. Med.*, vol. 182, no. 7, pp. e1883–e1891, 2017, doi: 10.7205/MILMED-D-16-00371.
- [4] World Health Organization, "Cancer." Accessed: May 02, 2024. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/cancer>
- [5] W. D. Travis, "Pathology of Lung Cancer," *Clin. Chest Med.*, vol. 32, no. 4, pp. 669–692, 2011, doi: 10.1016/j.ccm.2011.08.005.
- [6] L. Succony, D. M. Rassl, A. P. Barker, F. M. McCaughan, and R. C. Rintoul, "Adenocarcinoma spectrum lesions of the lung: Detection, pathology and treatment strategies," *Cancer Treat. Rev.*, vol. 99, no. May, p. 102237, 2021, doi: 10.1016/j.ctrv.2021.102237.
- [7] S. Huang, J. Yang, S. Fong, and Q. Zhao, "Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges," *Cancer Lett.*, vol. 471, no. December 2019, pp. 61–71, 2020, do 10.1016/j.canlet.2019.12.007.
- [8] T. Aitazaz, A. Tubaishat, F. Al-Obeidat, B. Shah, T. Zia, and I Tariq, "Transfer learning for histopathology images: an empiric study," *Neural Comput. Appl.*, vol. 35, no. 11, pp. 7963–7974, 2022, doi: 10.1007/s00521-022-07516-7.
- [9] M. Ali and R. Ali, "Multi-Input Dual-Stream Capsule Network for Improved Lung and Colon Cancer Classification," *Diagnostics*, vol. 11, no. 8, 2021, doi: 10.3390/diagnostics11081485.
- [10] N. Kumar, M. Sharma, V. P. Singh, C. Madan, and S. Mehandia, "An empirical study of handcrafted and dense feature extraction techniques for lung and colon cancer classification from histopathological images," *Biomed. Signal Process. Control*, vol. 7, p. 103596, 2022, doi: <https://doi.org/10.1016/j.bspc.2022.103596>.
- [11] N. yahia Ibrahim and A. S. Talaat, "An Enhancement Technique to Diagnose Colon and Lung Cancer by using Double CLAHE and Deep Learning," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 8, 2022, doi: <https://doi.org/10.14569/IJACSA.2022.0130833>.
- [12] J. Fan, J. Lee, and Y. Lee, "A Transfer Learning Architecture Based on a Support Vector Machine for Histopathology Image Classification," *Appl. Sci.*, vol. 11, no. 14, 2021, doi: 10.3390/app11146380.
- [13] M. A. Talukder, M. M. Islam, M. A. Uddin, A. Akhter, K. F. Hasa and M. A. Moni, "Machine learning-based lung and colon cancer detection using deep feature extraction and ensemble learning," *Expert Syst. Appl.*, vol. 205, p. 117695, 2022, doi: <https://doi.org/10.1016/j.eswa.2022.117695>.
- [14] S. Mangal, A. Chaurasia, and A. Khajanchi, "Convolution Neural Networks for diagnosing colon and lung cancer histopathological images." 2020.
- [15] K. Adu, Y. Yu, J. Cai, K. Owusu-Agyemang, B. A. Twumasi, and J Wang, "DHS-CapsNet: Dual horizontal squash capsule networks for lung and colon cancer classification from whole slide

- 4, pp. 2015–2092, 2021, doi: <https://doi.org/10.1002/ima.22569>.
- 16] A. A. Borkowski, M. M. Bui, L. B. Thomas, C. P. Wilson, L. A. DeLand, and S. M. Mastorides, “Lung and Colon Cancer Histopathological Image Dataset (LC25000),” pp. 1–2, 2019.
- 17] J. M. JR Goldblum, LW Lamps, *Rosai and Ackerman’s Surgical Pathology*. 2017.
- 18] C. Ieracitano, N. Mammone, A. Bramanti, A. Hussain, and F. C. Morabito, “A Convolutional Neural Network approach for classification of dementia stages based on 2D-spectral representation of EEG recordings,” *Neurocomputing*, vol. 323, pp. 96–107, 2019, doi: 10.1016/j.neucom.2018.09.071.
- 19] S. Han, H. Mao, and W. J. Dally, “Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding,” *4th Int. Conf. Learn. Represent. ICLR 2016 - Conf. Track Proc.*, pp. 1–14, 2016.
- 20] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- 21] A. Vaswani, N. Shazeer, and N. Parmar, “Attention is All You Need,” in *31st Conference on Neural Information Processing Systems* [22] A. Dosovitskiy, L. Beyer, A. Kolesnikov, and D. Weissenborn, “A Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” in *ICLR 2021*, 2021.
- [23] B. H. M. van der Velden, H. J. Kuijf, K. G. A. Gilhuijs, and M. A. Viergever, “Explainable artificial intelligence (XAI) in dee learning-based medical image analysis,” *Medical Image Analysis*, vol. 79. Elsevier B.V., Jul. 01, 2022. do 10.1016/j.media.2022.102470.
- [24] M. T. Ribeiro, S. Singh, and C. Guestrin, “‘Why Should I Trust You’: Explaining the Predictions of Any Classifier,” *NAACL-HLT 2016 2016 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang Technol. Proc. Demonstr. Sess.*, pp. 97–101, 2016, do 10.18653/v1/n16-3020.
- [25] G. Marques, D. Agarwal, and I. de la Torre Díez, “Automate medical diagnosis of COVID-19 through EfficientNet convolution neural network,” *Appl. Soft Comput.*, vol. 96, p. 106691, 2020, do <https://doi.org/10.1016/j.asoc.2020.106691>.

Özgeçmişler




Delal Şeker, Diyarbakır Rekabet Kurumu Anadolu Lisesi'nden mezun olduktan sonra (2011) lisans (2012-2016) ve yüksek lisans (2018-2020) eğitimini Dicle Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde tamamladı. 2021 yılından beri doktora eğitimi aynı bölümde devam etmektedir. TÜBİTAK 1001 Projesi kapsamında 'Kantitatif Sentetik Prostat Manyetik Rezonans Görüntülemeye Makine Öğrenmesi ile Prostat Kanserinin Değerlendirilmesi' başlıklı projesinde doktora bursiyeri olarak araştırmalarını sürdürmektedir.



Mustafa Said Kartal, 1998 yılında Afyonkarahisar'da doğdu. İlköğretim ve ortaöğretim eğitimini Afyonkarahisar'da tamamladı. 2018 yılında Sivas Cumhuriyet Üniversitesi Tıp Fakültesi'ne başladı. 2021 yılında hastane yazılımları üreten bir şirkette Veri Bilimci olarak çalışmaya başladı. Nisan 2023'ten beri tıp eğitimine devam ederken Hevi Al'da Makine Öğrenimi Mühendisi olarak görev yapmaktadır.



Abdulnasır Yıldız, Lisans Eğitimini 9 Eylül Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde tamamladıktan sonra (1997) yüksek lisans (2002) ve doktorasını (2011) Fırat Üniversitesinde bitirmiştir. Şu anda Dicle Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde Doçent olarak görev yapmaktadır. Ana araştırma ilgi alanları işaret işleme ve örüntü sınıflandırmadır.



İlkay Öksüz, İstanbul Alman Lisesinden mezun olduktan sonra lisans eğitimini İstanbul Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde tamamlamıştır. Daha önce, King's College London Biyomedikal Mühendisliği Bölümü'nde araştırma görevlisi olarak çalışmıştır. Doktora eğitimini, İTÜ İleri Araştırmalar Okulu'nda Bilgisayar, Karar ve Sistem Bilimleri alanında tamamlamıştır. Ana araştırma ilgi alanları görüntü segmentasyonu, görüntü kaydırma ve makine öğrenimidir. Şu anda İstanbul Teknik Üniversitesi Bilgisayar Mühendisliği bölümünde Doçent olarak görev yapmaktadır.