



## BÖBREK TÜMÖRÜ TESPİTİ İÇİN DERİN ÖĞRENME YÖNTEMLERİNİN KARŞILAŞTIRMALI ANALİZİ

Caner KARADAĞ<sup>1</sup>, Durmuş ÖZDEMİR<sup>2</sup>

<sup>1</sup>Dumlupınar Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Bölümü, Kütahya,  
[caner.karadag0@ogr.dpu.edu.tr](mailto:caner.karadag0@ogr.dpu.edu.tr), ORCID: 0000-0003-1856-2880

<sup>2</sup>Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, [durmus.ozdemir@dpu.edu.tr](mailto:durmus.ozdemir@dpu.edu.tr),  
ORCID: 0000-0002-9543-4076

*Geliş Tarihi(Received Date):24.09.2022*

*Kabul Tarihi(Accepted Date):02.12.2022*

### ÖZ

Günümüzde böbrek tümörü vakalarına oldukça sık rastlanmaktadır. Hastanın böbreğindeki tümör; büyüklük ve bölgesel olarak farklılık gösterebilir. Tümörün bir uzman tarafından doğru tespit edilememesi, geç teşhis ve erken tedavi uygulanmaması halinde hastalar çok ciddi riskler ile karşı karşıyadır. Doğru ve hızlı teşhis için literatürde yapay zeka teknolojilerine dayalı karar destek sistemlerinin önemli çözüm önerileri sunduğu görülmektedir. Tıp alanı yapay zekanın en çok kullanıldığı alanların başını çekmektedir. Böbrek tümörlerin tespitinde bilgisayarlı tomografi tıbbi görüntüleme cihazları yaygın olarak kullanılmaktadır. Bu çalışma kapsamında, bilgisayarlı tomografi cihazı tarafından üretilen görüntüler kullanılmıştır. Böbrek tümörü tespit analizi için sınıflandırıcı model olarak Convolutional Neural Network (CNN) kullanılmıştır. VGG16, VGG19 ve ResNET50 modelleri kullanarak aralarındaki performans karşılaştırma analizi yapılmıştır. Uygulamanın yazılım dili olarak Python ile Tensorflow, Keras ve OpenCV kütüphaneleri kullanılmıştır. Yapılan analiz tespiti sonucunda böbrek tümörlerinin saptanmasında %85'lere varan oranda tespitin başarılı şekilde gerçekleştirildiği görülmüştür.

**Anahtar kelimeler:** *Görüntü İşleme, Derin Öğrenme, Yapay Zekâ, Böbrek Tümörü*

### COMPARATIVE ANALYSIS OF DEEP LEARNING METHODS FOR RENAL TUMOR DETECTION

#### ABSTRACT

Kidney tumors are very common nowadays. Tumor in the patient's kidney; may vary in size and region. If the tumor cannot be detected correctly by a specialist, late diagnosis and early treatment are not applied, patients are at risk of death. In such cases, the importance of technology becomes clear. With the rapid development of technology, the concept of artificial intelligence has become the center of our lives in recent years. Medicine is also one of the areas where this concept is used the most. Computed tomography medical imaging devices are widely used in the detection of kidney tumors. Within the scope of this study, images obtained by computerized tomography device were used. Convolutional Neural Network (CNN) was used as the classifier model for kidney tumor detection analysis. Performance comparison analysis between them was made using VGG16, VGG19 and

ResNET50 models. Python and Tensorflow, Keras and OpenCV libraries were used as the software language of the application. As a result of the analysis, it was seen that it was successfully performed in the detection of kidney tumors.

**Keywords:** *Image Processing, Deep Learning, Artificial Intelligence, Kidney Tumor*

## 1. GİRİŞ

Dünya da gelişen teknoloji ile birlikte yapay zekâ ve alt kümesi olan derin öğrenme teknolojileri birçok farklı alanda hayatımızı kolaylaştıran bir unsur haline gelmiştir. Derin öğrenme, beyindeki nöron ağını taklit eden bir bilgisayar yazılımıdır. Derin öğrenme ifadesi 2012 yılında Hinton tarafından çok katmanlı yapay sinir ağlarının verimli bir şekilde eğitilebileceği ortaya koyulduktan sonra literatürde kullanılmaya başlanmıştır [1]. Sağlık hizmetleri faaliyet alanı da bunlardan biridir. Tıbbi alanda kullanılan yapay zekâ, medikal görüntüleme cihazlarından elde edilmiş görüntülerden çıkarım yapmamıza olanak sağlamaktadır. Medikal görüntüleme tekniklerinde yapay zekâ ile birlikte klinikteki verimliliği artırıp daha etkin kullanılması hedeflenmiştir [2].

Çevresel faktörlerin yanı sıra genetik olarak gelen bazı hastalıkların artmasıyla birlikte günümüzde sağlık hizmetlerinde medikal cihazların da kullanımında artış olmuştur. Ayrıca herhangi bir hastalığı olan bireyin medikal görüntüsünün uzman tarafından incelenmesinin yanında, yapay zekâ ve derin öğrenme teknolojileri içeren yazılım ile ilgili uzmanı destekleyici analizler yapıp verdiği rapor ile teşhis, tedavi ve karar süreçlerine destek veren yazılımlar bulunmaktadır [3].

Radyoloji, tıbbın alt ve önemli dallarından biridir. Bu alanda içinde farklı problemler ve anormalliklerin teşhislerine yardımcı olabilmek için hekimlerin kullandığı farklı tanısal medikal görüntüleme sistemleri mevcuttur. Medikal görüntüleme sistemi tercihi, hastanın semptomlarına, yöntemin maliyetine ve görüntüleme yapılan ilgili bölgeye ve kullanılabilirliğine bağlı olarak değişmektedir. Tespit edilen tümör hücreleri, büyüklüğü ve kıvamı gibi birçok farklı morfolojik özelliğe sahip olmaktadır. Tümörlü hücrelerin çoğunluğu beyin bölgesinde görülmekte olup, diğer hücrelere bakıldığında farklı bir yapıya sahiptirler. Böbrek bölgesinde bulunan tümörlerin analizi ve tespiti için Bilgisayarlı Tomografi (BT) taramaları ve Manyetik Rezonans (MR) taramaları en çok kullanılan medikal tespit görüntüleme türlerindedir [4].

Genel olarak böbrek tümörleri iyi veya kötü olarak tanılandırılrsa da aralarında birçok fark bulunmaktadır. Bunların en önemli olanı iyi huylu tümörlerin kanserli hücreler olmamasıdır. Burada iyi huylu olan böbrek tümörlerinin boyutlarının belli olması, tedavi edilmesini daha kolaylaştıracaktır. Diğer doku ve organlara dağılmayıp etkili oldukları alan kısıtlıdır. Böbrek tümörleri eğer kötü huylu bir tümör ise bunlar kanserli hücreler olmaktadır. Kanserli hücreler çok hızlı bir şekilde büyüyüp çoğaldığı için buldukları organda ve vücudun diğer alanlarında ciddi tahribata neden olmaktadır [5].

Medikal görüntüleme teknikleri beyin tümörü, böbrek ve meme kanseri, böbrek taşı tespiti gibi birçok tıbbi alanda yaygın olarak kullanılmaktadır [6]. Tıbbi cihazlardan elde edilmiş büyük medikal görüntü veri setlerini hızlı ve kolay bir şekilde yapay zekâ teknolojilerini kullanarak, hastalıkların teşhisi ve tedavi süreçleri çok önemli bir yere sahip olmaya başlanmıştır.

Medikal görüntüleme Wilhelm Conrad Roentgen'in 1895 yılında tesadüfen X-ışınlarını keşfetmesi ile başlamıştır ve günümüzde radyografi, nükleer medikal görüntüleme, ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans gibi farklı görüntüleme teknikleri ile gelişmeye devam etmektedir.

Her bir görüntüleme tekniğinin amacı hasta vücuduna ait bir parametrenin, özelliğın veya işlevin uzaysal haritalamasını yapmaktır [7].

Shi Yin vd., otomatik ultrason görüntüsü böbrek segmentasyonu için Müteakip Sınır Mesafesi ve Pixelwise Sınıflandırma ağlarını (SBD-PCN) önerdi. İlk olarak, Yazarlar, Ultrason (ABD) görüntülerinden yüksek seviyeli görüntüler için görüntüleri sınıflandırmak için önceden eğitilmiş derin sinir ağlarını bildirdiler, daha sonra bu işlevleri bir orta mesafe regresyon ağı ile böbrek sınırları haritalarının öğrenilmesi için girdi olarak kullandılar ve son olarak tanınanları sınıflandırdılar. Sınır mesafesi, bir piksel sınıflandırma ağı ile böbrek piksellerine dönüştürülür. Böbrek görüntüsünün segmentasyonu, nihai bir öğrenme yöntemiyle böbrek ve böbrek sınırlarını tahmin etmek için derin CNN'lere dayanmaktadır [8].

Njoud Abdullah Almansour vd., kronik böbrek hastalığının tahmini için Yapay Sinir Ağı ve Destek vektör makinesini (ANN-SVM) önerdi. Tüm eksik veri değerleri, gerçekleştirilecek deneyler için ilgili özniteliklerin ortalaması ile değiştirilmiştir. Daha sonra, sayısal analize dayalı olarak Yapay Sinir Ağı (YSA) ve Destek Vektör Makineleri (SVM) ile optimal parametreler hesaplanır. Ayrıca, Destek Vektörü ve Yapay Sinir Ağı için Optimize edilmiş parametreler belirlendi [9].

Tıbbi uygulamalarda Thong, Kadoury, Piché ve Pal [10] sağlıklı böbreklerin segmentasyonunu gerçekleştirmek için CNN'yi kullanmıştır. Ağları tamamen evrişimli değildir ve her pikseli bir pencere aracılığıyla ayrı ayrı sınıflandırır. Böbreğin tüm kısımlarını segmentlere ayırmak için bu pencereyi görüntü boyunca hareket etmesini sağladılar. Zhou vd. [11], organların bulanık lokalizasyonu (sınırlayıcı kutu), her 2B dilimin segmentasyonu ve çoğunluk oylaması yoluyla 2B dilimlerden bilgisayarlı tomografi taramalarının üç yönde 3B segmentasyonunu önermektedir. Sonuçlar iyiydi, ancak tümör bir böbreği segmentlere ayırma girişiminde bulunulmadı, bu nedenle bir zorluk ortaya çıktı. Evrişimsel ağlar, bu organların şekillerini tanımak için önce eğitilmelidir.

Yang vd. [17] böbrek tümörlerinin değerlendirilmesi için SCNN kullanımını tartıştıkları bir çalışma yayınladılar. Ağ yapısını ve Piramit ayrıştırma modülünü oluşturduktan sonra, daha fazla veri bulmak için iki yönlü bir segmentasyon tekniği kullandılar. Kayıp fonksiyonu hesaplandıktan sonra sınıflandırma için VGG16, ResNet vb. gibi farklı türde algoritmalar kullanılmıştır.

Attic Khan vd. [18] beyin tümörü sınıflandırması için transfer öğrenme tabanlı bir DL çerçevesi önerdi. Otomatik öznitelik çıkarımı için iyi bilinen iki önceden eğitilmiş ağ, yani VGG16 ve VGG19 kullandılar. Deney için popüler Beyin Tümörü Segmentasyonu (BraTs) veri seti kullanıldı. Ayrıca, uygun öznitelik seçimi için korrentropi ve kısmi en küçük kare tabanlı yöntem kullanılmış ve tek bir matriste birleştirilmiştir. Son olarak, ekstrem öğrenme makinesi (ELM) tabanlı bir sınıflandırıcı kullanılmış ve BraTs2015, BraTs2017 ve BraTs2018 veri setlerinde sırasıyla %97.8, %96.9, %92.5'lik en yüksek doğruluk elde edilmiştir.

Shen Li vd. mamogramlar kullanarak meme kanserini tespit etmek için bir evrişim sinir ağı yöntemine dayalı bir derin öğrenme algoritması oluşturdu. Bulguları, heterojen mamografi platformlarında gelişmiş performans ve doğruluk gösterdi. Deneyleri CBIS-DDSM veri setinden sayısallaştırılmış film mamogramları üzerinde gerçekleştirdiler. VGG16 ve ResNet50 kombinasyonunu ve sınıflandırıcılar [19], [20] olarak dört en iyi model kombinasyonundan oluşan bir başka topluluğu kullanarak gerçekleştirmiştir.

Bu çalışmada böbrek tümörü bulunan hastalara yönelik Python tabanlı derin öğrenme uygulaması geliştirilmiştir. Uygulamanın dili Python olduğu için web, masaüstü veya mobil uygulama gibi farklı platformlara entegre edilebilecek şekilde geliştirilmesi sağlanabilir. Uygulamanın asıl amacı; teşhis sırasında oluşan zaman kaybı ve hataların önüne geçmek ve ilgili uzmanın gözünden kaçabilecek herhangi bir bulguyu daha öncesinden analiz edip karar destek ve hastalığın tespit edilmesi süreçlerine katkı sağlamaktır.


## 2. DENEYSEL ÇALIŞMALAR ve DEĞERLENDİRME

### 2.1. Kullanılan Yöntemler

Bu çalışmada böbrek analizi için derin öğrenme sınıflandırıcı model olarak Convolutional Neural Network (CNN) ve aktivasyon fonksiyon olarak softmax kullanılmıştır. Sınıflandırıcı modellerin arasındaki performans analizini tespit etmek için VGG16, VGG19 ve ResNET50 modelleri kullanılmıştır.

#### 2.1.1. CNN model

Bilgisayarlar, görüntüleri piksellerinin değerlerine göre işlemektedir.  $30 \times 30$  renkli bir görüntünün (RGB olarak) işlenmesi 2700 piksel ( $30 \times 30 \times 3$ ) gerektirir. Bir veri parçasındaki temel ilişkiler, nöron katmanlarından oluşan bir sinir ağı kullanılarak bulunur. Tam bağlantılı sinir ağlarında,  $30 \times 30 \times 3$  piksellik bir giriş görüntüsü için ilk gizli katmandaki ağırlık sayısı 2700'dür.  $250 \times 250 \times 3$  piksellik bir giriş görüntüsü kullanan ilk gizli katman, 187.500 değerinde ağırlığa sahip olacaktır. Sonuç olarak, birçok parametreyle uğraşmak ve derin ağlardaki nöron sayısını artırmak zorunda kalınmaktadır. Bir CNN'nin yönetmesi gereken daha az ağırlığı ve daha az nöronu vardır. Çünkü her nöron önceki katmandaki tüm nöronlardan ziyade sadece az sayıda nörona bağlanır. Böylece CNN, görüntü sınıflandırmasında tam bağlantılı sinir ağlarından daha iyi performans gösterir [15]. CNN mimarisi iki katman gerektirir. Bunlar evrişim katmanları ve havuz katmanlarıdır. Aşağı havuzlama katmanı, öznetelik haritalarını, çıkarmak için evrişimsel katman tarafından evrişimsel olarak işlendikten sonra örnekleme yapar. Evrişimli sinir ağlarında çoklu gizli katmanlar ve çok sayıda parametre, görüntüler için sınıflandırma görevlerinde son derece iyi performans gösterir [16].




Şekil 1. CNN Mimarisi [21].


#### 2.1.2. VGG16 ve VGG19 model

VGG16, Simonyan ve Zisserman [14] tarafından geliştirilmiş bir CNN modelidir. ILSVRC 2014 yarışmasına sunulan en dikkat çekici modellerden biridir. Bu model, ImageNet veri setinde %92,7'lik

ilk 5 test doğruluğuna ulaşır. Toplamda, ağıın 16 katmanı vardır [14]. VGG16, daha önceki modellerde kullanılan büyük çekirdek boyutlu filtrelerin yerini alan birden fazla 3X3 çekirdek boyutunda filtreyi birbiri ardına tanıttı. Birden çok çekirdek katmanı, sinir ağıının derinliğinin artmasına neden olur. Bu, sinir ağıının daha karmaşık özellikleri ve kalıpları anlamasını ve tanımasını sağlar. Vgg16, 3x3 boyutlu evrişimli katmanları, 2x2 boyutlu ortalama havuzlama katmanlarını ve tam bağlantılı katmanları içerir. Sinir ağıının ilk genişliği 64'tür. Sinir ağıının genişliği her bir havuzlama katmanından sonra ikiye katlanır. İlk iki tam bağlantılı katman, her biri 256 kanala sahiptir ve üçüncü katman iki kanala sahiptir. İlk iki gizli katman, ReLU etkinleştirme işlevini kullanır ve son katman, bir softmax etkinleştirme işlevini kullanır. Her 256 kanal yoğun katmandan sonra bırakma uygulanmıştır. Ağıın öğrenme oranı 0.0001'dir. VGG16'nın bir varyantı olan Vgg19, esas olarak görüntü sınıflandırması için kullanılan 19 katmanlı bir evrişimsel sinir ağıdır. Temel mimarisi VGG16'ninkine benzer [14]. VGG19'daki tek fark, 256 ve iki kanallı 2 yoğun katmanın kullanılması ve öğrenme oranının 0,00001'e düşürülmesidir. VGG16 mimarisi Şekil 2, VGG19 mimarisi Şekil 3'de yer verilmiştir.



Şekil 2. VGG16 Mimarisi [22].

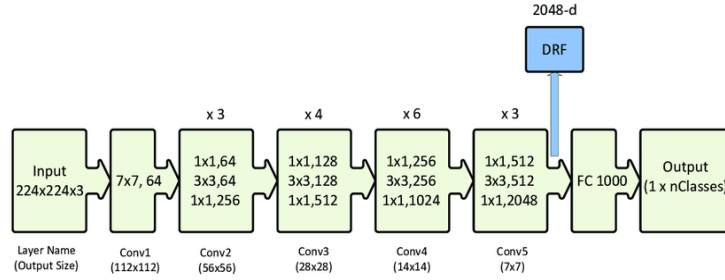


Şekil 3. VGG19 Mimarisi [23].

### 2.1.3. ResNET50 model

CNN öznetelikleri konvolüsyonel filtreler yoluyla çıkardıkları ve geri yayılım yoluyla parametreleri eğittikleri için temsil öğrenmede çok etkili olduklarını kanıtladığından, ImageNet veri kümesinde önceden eğitilmiş, son teknoloji evrişimli sinir ağı ResNet50[13] kullanılır. Resimler, ResNet50'nin giriş gereksinimlerine uyması için 224x224 olarak yeniden boyutlandırılır. Öznetelikler, 2048 boyutlu

öz nitelik vektörünü elde etmek için son tam bağlı katman kaldırılarak elde edilir. Bu özellik vektörleri, fazla hesaplama gücü kullanılmadan kolayca elde edilir. ResNET50 mimarisi Şekil 4'te gösterilmiştir.



Şekil 4. ResNET50 Mimarisi [24].

## 2.2. Kullanılan Görüntü Veri Seti

Tümörlerin segmentasyonunu ve sınıflandırılmasını sağlamak için Kaggle'da açık kaynak olarak bulunan (Kidney Disease Classifier) veri seti kullanılmıştır [12]. Veri seti eğitim için normal tümörsüz 4560 ve tümörlü 2054 görüntü, testi için ise normal tümörsüz 255 ve 155 tümörlü görüntüsü içermektedir. Yalnızca tümör görüntülerinden oluşturulmuş yüksek kaliteli, dengeli bir test ve doğrulama veri seti oluşturulmuştur. Bu nokta çok önemlidir, çünkü modelin belirli bir tümörün görüntüsünden öğrenirse, aynı tümörün başka bir görüntüsü üzerinde kontrol edilirse doğruluğumuz gerçekçi olmayacaktır.

## 2.3. Sağlıklı Böbrek


Uygulama için daha önce tespit edilmiş sağlıklı böbrek bilgisayarlı tomografi cihazından elde edilmiş farklı sağlıklı bireylerin böbrek görüntüleri Şekil 5'te yer verilmiştir.



Şekil 5. Sağlıklı Böbrek Görüntüleri [12].

## 2.4. Böbrek Tümör Olan Görüntüler

Burada 3 farklı bireye ait tomografi görüntüsü bulunmaktadır. Farklı noktalarda böbreklerin tümörlü olduğu görülmektedir.



Şekil 6. (a) da sol böbreğin alt bölümünde, şekil (b) de sağ böbreğin tamamını ve vücudun büyük bölümünü, şekil (c) de ise böbreğin sağ alt kısmında tümörlü alan işaretlenmiştir [12].

## 2.5. Parametrelerin Belirlenmesi

Uygulamada CNN, VGG16, VGG19 ve ResNet50 sınıflandırıcı modellerinin parametreleri Çizelge 1’de gösterilmiştir.

Çizelge 1. Parametre Değerleri.

Giriş Boyutu	Model	Parti Boyutu	Eğitim Sayısı	Tur Sayısı	Toplam Sınıf Sayısı	Sınıf Ayrıntılı	Test Boyutu	Rastgele Durum	Karıştırma
224	CNN	20	5	5	5	1	0.3	0	false
224	VGG16	20	5	5	5	1	0.3	0	false
224	VGG19	20	5	5	5	1	0.3	0	false
224	ResNet50	20	5	5	5	1	0.3	0	false

## 2.6. Model’in Eğitilmesi

Modelin eğitilmesi için aktivasyon fonksiyonu softmax kullanarak Convolutional Neural Network (CNN) sınıflandırıcı modeli ile eğitilmiştir. Eğitilecek olan verilerin sağlıklı bireylerden 1500 tane ve böbrek tümörü olan 1500 tane bireyin bilgisayarlı tomografi görüntüsü sisteme eklenir. İlk etapta eğitilen veri seti başlangıçta ortalama %59’lük doğruluğa sahip olmasına karşın son aşamaya geldiğinde eğitilmiş veri seti %79 doğruluğa ulaşmaktadır. Eğitilen veri setinde kayıp değeri ise başlangıçta %67 iken son aşamaya geldiğinde %47’lik bir kayıp değerine ulaşmıştır. (CNN) sınıflandırıcı modeline ait eğitim sonuçları Çizelge 2’de gösterilmiştir.

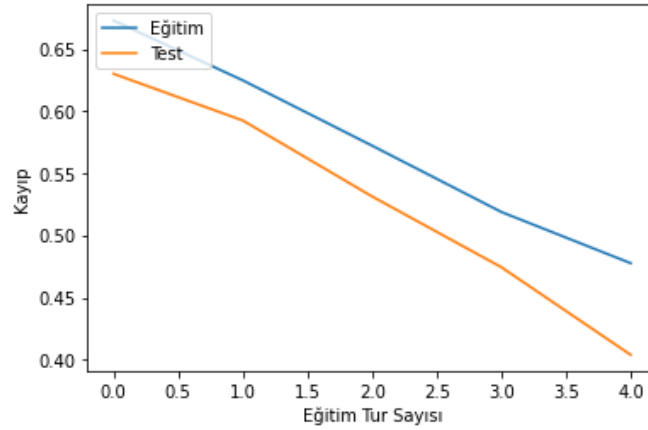
Çizelge 2. Eğitim Sonuçları.

Eğitim Sayısı	Tur Kayıp Değeri	Doğruluk	Doğrulama Kaybı	Doğrulama Doğruluğu
1	0.6731	0.5971	0.6302	0.6566
2	0.6249	0.6721	0.5926	0.6591
3	0.5724	0.7259	0.5315	0.7855
4	0.5190	0.7626	0.4746	0.8279

5 0.4778 0.7912 0.4040 0.8532

### 2.7. Kayıp Grafiği


CNN modeli ve softmax aktivasyon fonksiyonu ile eğitilen verilerin eğitim sırasında oluşan kayıp değerleri Şekil 7’de ki grafikte yer verilmiştir. Burada görüldüğü gibi eğitim tur sayımı attıkça kayıp değeri 0 değerine yaklaştığı görülmüştür.



Şekil 7. Böbrek Tümörü Kayıp Grafiği.

### 2.8. Doğruluk Grafiği

CNN model ve aktivasyon fonksiyonu softmax ile eğitilen verilerin eğitim sırasında oluşan doğruluk değerleri Şekil 8’de ki grafikte yer verilmiştir. Başlangıçta test değeri yaklaşık %65 seviyede gitmesine karşın eğitim tur sayısı 1 değerine geldikten sonra doğruluk değeri yaklaşık %84’ten yukarı doğru gittiği görülmüştür. Bununla birlikte oluşun metrik sonuçları Çizelge 3’te gösterilmiştir.



Şekil 8. Böbrek Tümörü Doğruluk Grafiği.



**Çizelge 3.** Metrik Sonuçları.

	Keskinlik	Geri Çağırma	F1 Puanı	Destek
Sağlıklı	0.88	0.90	0.89	805
Tümörlü	0.79	0.77	0.78	421
Doğruluk	-	-	0.85	1226
Makro Ortalama	0.84	0.83	0.84	1226
Ağırlıklı Ortalama	0.85	0.85	0.85	1226

### 2.9. Böbrek Tümörü İçin Sınıflandırıcı Aralarındaki Performans Farkları


Uygulamada 4 farklı sınıflandırıcı modelin yanı sıra aktivasyon fonksiyonu softmax kullanılmıştır. Burada softmax aktivasyon fonksiyonu ile sınıflandırıcı modeller aralarındaki performans analiz sonuçları Çizelge 4’de gösterilmiştir.

**Çizelge 4.** Sınıflandırıcı Performans Sonuçları.

Sınıflandırıcı	Kayıp Değeri	Doğruluk Değeri	Doğrulama Kaybı	Doğrulama Doğruluğu
CNN	0.4778	0.7912	0.4040	0.8532
VGG 16	0.0952	0.9793	0.0846	0.9794
VGG 19	0.0101	0.9991	0.0088	0.9980
ResNet50	0.4559	0.7955	0.4984	0.7443

### 2.10. Tümör Olup Olmadığı Tespiti


Softmax aktivasyon fonksiyonu ile eğitilen modelin eğildikten sonra böbrekte herhangi bir tümörlü bölge olup olmadığının tespiti Şekil 9’da yer verilmiştir. Şekilde görüldüğü gibi 12 farklı bireyin eğitilmiş verinin analizi sonucunda böbrek tümörlü ise (evet), tümörlü değilse (hayır) olacak şekilde gösterilmesi sağlanmıştır.



Şekil 9. Böbrek Tümörü Analiz Sonuçları.

### 2.11. Tümörün Konum Tespiti


Softmax aktivasyon çıkış fonksiyonu kullanılarak CNN sınıflandırıcı eğitilen modelin böbrekte tümörlü bölgenin tespit edilmesi için 9 adım da maskeleme ve filtreleme işlemleri uygulanarak tümör konumun tespiti aşamaları Şekil 10'da yer verilmiştir.



Şekil 10. Böbrek Tümörü Analiz Sonuçları.

### 2.12. Tümör Konum ve Ölçüm Tespiti

Uygulamanın son aşamasında tümörün böbrek bölgesindeki yerinin tespiti, genişliği ve yüksekliği bulunması sağlanmıştır. Aktivasyon fonksiyonu softmax ile eğitilen modelin, tümör konumu ve diğer ölçüm değerleri Şekil 11’de yer verilmiştir. Burada görüldüğü gibi tümörün genişliği 9,9 cm olmasına karşında yüksekliği 7,7 cm olarak bulunmuştur.



Şekil 11. Böbrek Tümörü Ölçüm Tespiti.

### 3. SONUÇ ve TARTIŞMA

Derin öğrenme ve yapay zekâ günümüz teknolojisinin vazgeçilmez bir parçası olmuştur. Birçok alanda kullanıldığı gibi tıp alanındaki uygulamalarında başarılı sonuçlar üretmektedir. Görüntü işleme, yapay zekâ ve derin öğrenme doğru bir şekilde uygulandığında tıp alanındaki uygulamalarda çok başarılı sonuçlar verebilir.

Tıbbi kaynakların kısıtlı ve radyologların yetersiz olduğu yerlerde geliştirilen derin öğrenme uygulamalarıyla böbrek tümörü veya böbrek taşı tespit etme çabasını en hızlı ve en doğru ortaya çıkartmasına yardımcı olabilir. Günümüzde de çevresel faktörlerin yanı sıra nüfusun fazla olmasıyla birlikte hastaneler de doktorların muayene yoğunluklarından dolayı ya da muayene sırasında doktorun gözden kaçabilecek bulguların önüne geçebilir. Bu sayede daha doğru sonuçlar elde edilip, hızlıca tedavi sürecine başlanacaktır.

Bu çalışmada böbrek tümörü ile sağlıklı bireylerin bilgisayarlı tomografi görüntü içeren veri seti kullanılıp derin öğrenme ile analiz edilmesi sağlanmıştır. Böbrek tümörü analiz için 1500 taneden fazla sağlıklı bireyin yanı sıra 1500 taneden fazla tümörlü BT görüntüsü kullanılmıştır. CNN model kullanılarak böbrek tümör verisini softmax aktivasyon fonksiyonu ile eğittiğimizde başlangıçta %59 doğruluk olmasına karşın son aşamaya gelindiğinde %79’luk bir doğruluğa ulaşılmıştır.

Sonuç olarak derin öğrenme ve medikal görüntülerden böbrek tümörü tespit etmek için ikili sınıflandırıcı oluşturuldu. Sınıflandırıcı olarak CNN (%85), aktivasyon transfer fonksiyonu olarak ise softmax kullanıldı. Bununla birlikte VGG16 (%97), VGG19 (%99) ve ResNet50 (%74) sınıflandırıcı modelleri kullanılarak aralarındaki performans farkları bulunması sağlandı. Gelecekte derin öğrenme ve medikal görüntüleme analiz yapıları tıp alanının vazgeçilmez bir parçası haline gelecektir.

Sonraki yapılacak çalışmalarda (Batch Size) değerini arttırdığımızda doğruluk değeri yüksek çıktığı görülmüştür. Doğruluk değerini yükseltmek için eğitim tur sayısını ve (Batch Size) arttırabiliriz. Fakat uygulamanın kurulduğu ortama veya performansına bağlı olarak eğitim zamanı uzadığı görülmüştür. Bununla birlikte derin öğrenme için daha fazla hasta kişinin verisi sisteme yüklendiğinde sistemin başarı oranını arttıracaktır.

## TEŞEKKÜR

Bu çalışma, Kütahya Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında Dr. Öğr. Üyesi Durmuş ÖZDEMİR Danışmanlığında Yüksek Lisans yapan Caner KARADAĞ'ın yüksek lisans tez çalışmalarından üretilmiştir

## KAYNAKÇA

- [1] Hinton, G. Deng, L. Yu, D. Dahl, G.E. Mohamed, A.-r. Jaitly, N. Senior, A. Vanhoucke, V. Nguyen, P. ve Sainath, T.N., (2012). "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups", IEEE Signal Processing Magazine, 29: 82-97.
- [2] Özdemir, D., Arslan, N. N., (2021), Analysis of Deep Transfer Learning Methods for Early Diagnosis of the Covid-19 Disease with Chest X-ray Images, 630p, 2021.
- [3] Canbay, P., (2020), Sağlıkta yapay zeka: derin öğrenme teknikleri ve uygulamaları, pp. 25-26
- [4] Dandil, E., (2015), Mr görüntüleri ve mr spektroskopisi verileri ile yapay öğrenme tabanlı beyin tümörü tespit yöntemi ve uygulaması, pp. 4-7
- [5] Böbrek Kanseri, Erişim Adresi: <https://www.medicalpark.com.tr/bobrek-kanseri-nedir/hg-1812>, Erişim: 24.03.2022.
- [6] Eker, A. G., Duru, N., (2021), Medikal görüntü işlemede Derin öğrenme uygulamaları, pp. 460-466, 2021.
- [7] Yıldırım, (2008), Medikal Görüntüleme Sistemleri İçin Yarıiletken Matris Dedektör Tasarımı ve Geliştirilmesi, 1p,7p.
- [8] Shi Yin, vd., (2020), Automatic kidney segmentation in ultrasound images using subsequent boundary distance regression and pixelwise classification networks, Med. Img. Anal. 60, 101602.

- [9] Njoud Abdullah Almansour, vd., (2019), Neural network and support vector machine for the prediction of chronic kidney disease: A comparative study, *Comput. Biol. Med.* 109 101–111.
- [10] Thong, W., Kadoury, S., Piché, N., ve Pal, C. J. (2016). Convolutional networks for kidney segmentation in contrast-enhanced ct scans. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 1–6. doi:10.1080/21681163.2016.1148636.
- [11] Zhou, X., Takayama, R., Wang, S., Zhou, X., Hara, T., ve Fujita, H. (2017). Automated segmentation of 3d anatomical structures on ct images by using a deep convolutional network based on end-to-end learning approach. In *Medical imaging 2017: Image processing*: 10133 (p. 1013324). International Society for Optics and Photonics. doi:10.1117/12.2254201.
- [12] Kidney Tumor and Stone MRI Images, Erişim Adresi: <https://www.kaggle.com/code/ahmedbadr22/kidney-disease-classifier-with-99-cnn/data>, Erişim: 26.04.2022
- [13] He, X. Zhang, S. Ren, and J. Sun, (2016), “Deep residual learning for image recognition”. In *CVPR*,
- [14] Simonyan, K., Zisserman, A., (2014), Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556
- [15] Bu X, Peng J, Yan J, Tan T, Zhang Z. GAIA: A transfer learning system of object detection that fits your needs. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*; 2021. p. 274–83.
- [16] Azeez RA, Abdul-Hussein MK, Mahdi MS, ALRikabi HTHS, (2021), Design a system for an approved video copyright over cloud based on biometric iris and random walk generator using watermark technique. *Period Eng Nat Sci* 10(1):178–87.
- [17] Pan, T., Yang, G., Wang, C., et al., (2019), “A multi-task convolutional neural network for renal tumor segmentation and classification using multi-phasic ct images,” in *2019 IEEE International Conference on Image Processing (ICIP)*, pp. 809–813. doi: 10.1109/ICIP.2019.8802924.
- [18] Khan, M.A., Ashraf, I., Alhaisoni, M., Damaševičius, R., Scherer, R., Rehman, A., S.Bukhari, S. A. C., (2020), Multimodal brain tumor classification using deep learning and robust feature selection: a machine learning application for radiologists *Diagnostics*, 10 (8) p. 565, 10.3390/diagnostics10080565
- [19] Sahu, B. P., Mohanty, S. N., Rout, S. K., (2019), A hybrid approach for breast cancer classification and diagnosis *EAI Endorsed Trans. Scalable Inf. Syst.*, 6(20) pp. 1-8
- [20] Sahu, B. P., Das, S., Mohanty, S. N., Rout, S. K., (2018), Ensemble comparative study for diagnosis of breast cancer data set *Int. J. Eng. Technol.*, 7 pp. 281-288
- [21] CNN mimarisi, Erişim Adresi: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, Erişim: 19.10.2022.

*Karadağ, C. ve Özdemir, D., Journal of Scientific Reports-B, Sayı 6, 10-23, Aralık 2022.*  
*Karadağ, C. and Özdemir, D., Journal of Scientific Reports-B, Number 6, 10-23, December 2022.*

---

- [22] VGG16 mimarisi, Erişim Adresi: <http://www.cs.toronto.edu/~frossard/post/vgg16/>, Erişim: 19.10.2022.
- [23] VGG19 mimarisi, Erişim Adresi: [https://www.researchgate.net/figure/illustration-of-the-network-architecture-of-VGG-19-model-conv-means-convolution-FC-means\\_fig2\\_325137356](https://www.researchgate.net/figure/illustration-of-the-network-architecture-of-VGG-19-model-conv-means-convolution-FC-means_fig2_325137356), Erişim: 19.10.2022.
- [24] ResNET50 mimarisi, Erişim Adresi: [https://www.researchgate.net/figure/ResNet-50-architecture-26-shown-with-the-residual-units-the-size-of-the-filters-and\\_fig1\\_338603223](https://www.researchgate.net/figure/ResNet-50-architecture-26-shown-with-the-residual-units-the-size-of-the-filters-and_fig1_338603223), Erişim: 19.10.2022.