



**T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ
ÜNİVERSİTESİ
TIP FAKÜLTESİ**

**RENAL SKORLAMA VE NEFREKTOMİ KARAR
SÜREÇLERİNDE YAPAY ZEKA TABANLI
ÇÖZÜMLER**

**Arş. Grv. Dr. Berkay EREN
TIPTA UZMANLIK TEZİ**

**DANIŞMAN
Prof. Dr. Haşmet SARICI**

ÜROLOJİ ANABİLİM DALI

AFYONKARAHİSAR 2025

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
TIP FAKÜLTESİ

Üroloji Anabilim Dalı

RENAL SKORLAMA VE NEFREKTOMİ KARAR
SÜREÇLERİNDE YAPAY ZEKA TABANLI ÇÖZÜMLER

Arş. Grv. Dr. Berkay EREN
TIPTA UZMANLIK TEZİ

Danışman
Prof. Dr. Haşmet SARICI

AFYONKARAHİSAR - 2025

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Tezi Hazırlayanın

Adı Soyadı: Berkay EREN

İmza :

Danışmanın

Ünvanı Adı Soyadı: Prof. Dr. Haşmet SARICI

İmza :

KABUL ONAY SAYFASI

T.C
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
TIP FAKÜLTESİ
ÜROLOJİ ANABİLİM DALI

Tez başlığı : Renal Skordama ve Nefrektomi Karar Süreçlerinde
Yapay Zeka Tabanlı Çözümler

Tezi hazırlayan : Arş. Grv. Dr. Berkay EREN

Tez Savunma Tarihi : 06.08.2025

Tez Kabul Tarihi : 06.08.2025

Tez Danışmanı : Prof. Dr. Haşmet SARICI

İş bu çalışma jürimiz tarafından ÜROLOJİ ANABİLİM DALI'nda TIPTA
UZMANLIK TEZİ olarak kabul edilmiştir.

JÜRİ:

BAŞKAN
Prof. Dr. Mustafa KARALAR
Afyonkarahisar Sağlık Bilimleri Üniversitesi Tıp Fakültesi
Üroloji A.D.

ÜYE
Prof. Dr. İbrahim KELEŞ
Afyonkarahisar
Sağlık Bilimleri Üniversitesi
Tıp Fakültesi
Üroloji A.D.

ÜYE
Prof. Dr. Haşmet SARICI
Afyonkarahisar
Sağlık Bilimleri Üniversitesi
Tıp Fakültesi
Üroloji A.D.

ONAY
DEKAN
Prof. Dr. Necip BECİT
Afyonkarahisar Sağlık Bilimleri Üniversitesi Tıp Fakültesi

TEŞEKKÜR

Uzmanlık eğitimim süresince bilgi ve deneyimlerinden her zaman istifade ettiğim, üzerimde emeği çok fazla olan ve tez sürecinde de yol göstericiliği ve desteğiyle her zaman yanımda olan değerli hocam ve tez danışmanım Prof. Dr. Haşmet SARICI'ya en içten teşekkürlerimi sunarım.

Uzmanlık eğitimim boyunca bilgi ve tecrübelerini benden esirgemeyen, gerek akademik çalışmalarda gerekse cerrahi nosyon kazanmamda ve etik ilkelere bağlı donanımlı bir hekim olarak yetişmemde büyük katkıları olan başta anabilim dalı başkanımız Prof. Dr. Mustafa KARALAR olmak üzere kıymetli hocalarım Prof. Dr. İbrahim KELEŞ, Doç. Dr. Arif DEMİRBAŞ, Doç. Dr. Abdullah GÜREL, Dr. Öğr. Üyesi Burhan BAYLAN, Dr. Öğr. Üyesi Veli Mert YAZAR, Dr. Öğr. Üyesi Kutay TOPAL ve Op. Dr. Osman GERÇEK'e teşekkür ederim.

Bu çalışmanın temelini oluşturan görüntüleme verilerine ulaşmamı sağlayan ve teknik süreçlerde bana yardımcı olan AFSÜ Hastanesi Radyoloji Anabilim Dalı'na ve Dr. Öğr. Üyesi Emin DEMİREL'e teşekkür ederim. Verilerin işlenmesi ve tez çalışmasındaki büyük katkılarından dolayı Dr. Burak TOZLUK'a teşekkür ederim. Verilerimin istatistiksel analizinde yardımcı olan değerli abim Dr. Öğr. Üyesi Bilal Atilla BEZEN'e teşekkür ederim.

Asistanlık sürecim boyunca birlikte güzel zamanlar geçirdiğimiz, mesleki gelişimimize katkı sağlarken aynı zamanda güzel bir dostluk ortamı oluşturduğumuz kıdemlim Dr. Kemal ULUSOY ve değerli ekip arkadaşlarım Dr. Melih ŞENKOL, Dr. Recep UZUN, Dr. Murat Cengizhan ATİK, Dr. Muhammed Ali ULUCAK, Dr. Mustafa Esat İNCE, Dr. Rahib GARAYEV, Dr. Ramazan GENCAN ve Dr. Mustafa Samet TURGUT'a teşekkür ederim.

Bu süreçte birlikte çalıştığım diğer branşlardaki abilerime, tüm asistan hekim arkadaşlarıma, servis ve ameliyathane hemşirelerimize, tıbbi sekreterlerimize ve tüm destek personelimize teşekkür ederim.

Benim her zaman yanımda olan ve beni her konuda destekleyen, bugünlere gelmemde şüphesiz en büyük katkıya sahip olan ve önümdeki başarı merdivenlerini çıkarken de her zaman yanımda olacağını bildiğim biricik ailem annem Serpil EREN, babam Necmettin EREN ve canım kardeşim Şebnem EREN'e sonsuz teşekkürlerimi sunarım.

Dr. Berkay EREN

Afyonkarahisar, Ağustos 2025

RENAL SKORLAMA VE NEFREKTOMİ KARAR SÜREÇLERİNDE YAPAY ZEKA TABANLI ÇÖZÜMLER

Arş. Grv. Dr. Berkay EREN

Afyonkarahisar Sağlık Bilimleri Üniversitesi
Tıp Fakültesi Üroloji Anabilim Dalı Tıpta Uzmanlık Tezi
Ağustos 2025
Danışman: Prof. Dr. Haşmet SARICI

ÖZET

Amaç: Bu çalışmanın amacı, bilgisayarlı tomografi (BT) verileri üzerinden renal tümörlerin kompleksite düzeyini R.E.N.A.L. nefrometri skorlarına göre otomatik olarak sınıflandırabilen özgün bir derin öğrenme modeli geliştirerek, parsiyel ve total nefrektomi karar süreçlerine katkı sağlayacak klinik karar destek için altyapı oluşturmak ve gelecekteki yapılacak çalışmalara ışık tutmaktır.

Gereç ve Yöntem: Afyonkarahisar Sağlık Bilimleri Üniversitesi Üroloji Kliniği'nde nefrektomi uygulanmış ve histopatolojik olarak malign renal tümör tanısı almış 197 hastaya ait portal faz kontrastlı BT verileri kullanılmıştır. Görüntülerdeki tümör içeren böbrek dokusu 128×128×64 voksel boyutuna yeniden örneklenmiş ve bu işlemler manuel olarak belirlenmiştir. Segmentasyon ön işlemi gerektirmeyen, sıfırdan geliştirilen bir 3 boyutlu konvolüsyonel sinir ağı (3D CNN) modeli ile tümör kompleksitesi “düşük” ve “yüksek” olarak sınıflandırılmıştır.

Bulgular: Modelin genel sınıflandırma doğruluğu %90, ROC analizinde AUC skoru 0.96 olarak hesaplanmıştır. Düşük kompleksite grubundaki tüm vakalar doğru sınıflandırılarak %100 duyarlılık elde edilmiştir. Yüksek kompleksite grubunda ise duyarlılık %76.9'dur. Tümör maksimum çapı ile nefrometri skoru arasında anlamlı pozitif korelasyon saptanmıştır ($r = 0.718$; $p < 0.001$). Modelin özellikle düşük kompleksite grubundaki başarısı, parsiyel nefrektomi için uygun olguların doğru saptanmasında yüksek güvenilirlik sunmaktadır.

Sonuç: Geliştirilen 3D CNN modeli, manuel skorlamalarda görülen subjektifliğe alternatif olarak, BT görüntülerinden doğrudan tümör kompleksitesi tahmini yapabilen hızlı ve tekrarlanabilir bir sistem sunmaktadır. Bu yönüyle model, cerrahların parsiyel veya total nefrektomi kararlarında destekleyici unsur olarak kullanılabilecek başarılı bir yapay zekâ uygulaması olarak görülebilir. Özellikle düşük kompleksiteli vakalarda sağlanan %100 duyarlılık oranı, bu teknolojinin preoperatif cerrahi planlama süreçlerine entegre edilebileceğini göstermektedir.

Anahtar Kelimeler: Bilgisayarlı Görüntüleme, Derin Öğrenme, Nefrektomi, Tümör Kompleksitesi, Ürolojik Tümörler

ARTIFICIAL INTELLIGENCE-BASED SOLUTIONS IN RENAL SCORING AND NEPHRECTOMY DECISION-MAKING PROCESSES

R.A.Dr. Berkay EREN

Afyonkarahisar University of Health Sciences
Faculty of Medicine, Department of Urology Thesis
August 2025
Advisor: Prof. Dr. Haşmet SARICI

ABSTRACT

Objective: The aim of this study is to develop a novel deep learning model capable of automatically classifying renal tumor complexity based on R.E.N.A.L. nephrometry scores using computed tomography (CT) data, thereby supporting clinical decision-making in partial and total nephrectomy procedures.

Materials and Methods: Contrast-enhanced portal phase CT data from 197 patients diagnosed with malignant renal tumors and who underwent nephrectomy at Afyonkarahisar Health Sciences University Urology Department were used. All CT images were resampled to 128×128×64 voxel dimensions, and tumor-containing kidney were manually delineated. A custom-built three-dimensional convolutional neural network (3D CNN) model was developed to classify tumors as “low” or “high” complexity without requiring segmentation preprocessing.

Results: The overall classification accuracy of the model was calculated as 90%, with an area under the ROC curve (AUC) of 0.96. All cases in the low-complexity group were correctly classified, achieving a sensitivity of 100%. In the high-complexity group, a sensitivity of 76.9% was obtained. A statistically significant and strong positive correlation was observed between tumor maximum diameter and nephrometry score ($r = 0.718$; $p < 0.001$). The model demonstrated high reliability in identifying cases suitable for partial nephrectomy, particularly within the low-complexity group.

Conclusion: The developed 3D CNN model offers a rapid and reproducible alternative to manual scoring systems by predicting tumor complexity directly from CT images. This capability has the potential to reduce subjectivity in surgical planning and support urologists in determining whether partial or total nephrectomy is more appropriate. The model’s 100% sensitivity in the low-complexity group highlights its promising role as an artificial intelligence-based clinical decision support tool for preoperative planning.

Keywords: Computed Imaging, Deep Learning, Nephrectomy, Tumor Complexity, Urologic Neoplasms

İÇİNDEKİLER

BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
KABUL ONAY SAYFASI	iii
TEŞEKKÜR	iv
ÖZET	v
ABSTRACT	vi
İÇİNDEKİLER.....	vii
SİMGELER VE KISALTMALAR DİZİNİ.....	ix
TABLolar DİZİNİ.....	xi
ŞEKİLLER DİZİNİ	xii
1. GİRİŞ VE AMAÇ.....	1
2. GENEL BİLGİLER	3
2.1. MALİGN BÖBREK TÜMÖRLERİ.....	3
2.2. EVRELEME VE SINIFLANDIRMA SİSTEMLERİ.....	4
2.2.1. Evreleme.....	4
2.2.2. R.E.N.A.L. Nefrometri Skorlama Sistemi.....	4
2.3. GÖRÜNTÜLEME.....	6
2.4. LOKALİZE RENAL HÜCRELİ KANSERİN TEDAVİSİ	6
2.5. TAKİP	7
2.6. YAPAY ZEKA (ARTİFİCİAL INTELLİGENCE, YZ, AI)	8
2.6.1. Derin Öğrenme (Deep Learning, DL).....	8
2.6.2. Konvolüsyonel Nöral Ağlar (CNN; Convolutional Neural Network, Evrişimli Sinir Ağları)	9
2.6.3. Konvolüsyonel Nöral Ağların Mimarisi.....	9
2.6.4. 3D Konvolüsyonel Sinir Ağı (3D-CNN).....	11
2.6.5. Nöral Ağların Eğitiminde Hiperparametreler	11

3. GEREÇ VE YÖNTEM	12
3.1. ÇALIŞMA GRUBU	12
3.2. VERİ TOPLAMA	12
3.3. VERİ HAZIRLAMA VE ÖN İŞLEME.....	13
3.4. DERİN ÖĞRENME MODELİ MİMARİSİ (3D CNN).....	15
3.5. MODEL EĞİTİMİ VE ÖĞRENME SÜRECİ.....	17
3.6. MODEL MİMARİSİ VE ÖZELLİK ÖĞRENME SÜRECİ	18
3.7. PERFORMANS ÖLÇÜTLERİ	19
3.8. KULLANILAN YAZILIMLAR VE ARAÇLAR.....	19
3.9. İSTATİSTİKSEL ANALİZ	20
3.10. GÜÇLÜKLER VE SINIRLAMALAR.....	20
3.11. ETİK VE YASAL UYGULAMALAR	21
4. BULGULAR	22
4.1. DEMOGRAFİK VE KLİNİK ÖZELLİKLER.....	22
4.2. TÜMÖR ÖZELLİKLERİNE AİT BULGULAR.....	23
4.3. KORELASYON ANALİZİ SONUÇLARI	25
4.4. ROC EĞRİSİ, AUC ANALİZİ VE MODEL PERFORMANSI.....	26
4.5. SINIFLANDIRMA METRİKLERİ	28
4.5.1. Konfüzyon Matrisi Yorumlanması	28
4.5.2. Model Performans Metriklerinin Değerlendirilmesi.....	30
5. TARTIŞMA.....	32
6. SONUÇLAR.....	44
7. KAYNAKÇA	46

SİMGELER VE KISALTMALAR DİZİNİ

2D	: İki boyutlu (Two-dimensional)
3D	: Üç Boyutlu (Three-Dimensional)
3D-CNN	: 3-Dimensional Convolutional Neural Network
AI	: Yapay Zeka (Artificial Intelligence)
AML	: Anjiyomiyolipom
AP	: Anterior/Posterior
AUC	: Eğri Altındaki Alan (Area Under the Curve)
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimsel Sinir Ağı (Convolutional Neural Network)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
DICOM	: Digital Imaging and Communications in Medicine
EAU	: Avrupa Üroloji Derneği (European Association of Urology)
F1-Score	: Harmonik Ortalama (Precision ve Recall'ün dengesi)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
HU	: Hounsfield Unit
ISUP	: Uluslararası Ürolojik Patoloji Derneği (International Society of Urological Pathology)
KBH	: Kronik Böbrek Hastalığı
LND	: Lenf Nodu Diseksiyonu
LPN	: Laparoskopik Parsiyel Nefrektomi
ML	: Machine Learning (Makine Öğrenimi)
MRG	: Manyetik Rezonans Görüntüleme
NKC	: Nefron Koruyucu Cerrahi
OS	: Genel Sağkalım (Overall Survival)
PN	: Parsiyel Nefrektomi
RCC	: Renal Hücreli Karsinom (Renal Cell Carcinoma)
R.E.N.A.L.	: Radius, Exophytic/endophytic properties, Nearness to collecting system or sinus, Anterior/posterior, Location relative to polar lines
RN	: Radikal Nefrektomi
ROC	: Alıcı Çalışma Eğrisi (Receiver Operating Characteristic)

ROI	: İlgil Alanı (Region of Interest)
RPN	: Robot Yardımlı Parsiyel Nefrektomi
TNM	: Tümör, Nod, Metastaz sınıflaması
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
US	: Ultrasonografi
VHL	: Von Hippel-Lindau sendromu
WHO	: Dünya Sağlık Örgütü (World Health Organization)



TABLÖLAR DİZİNİ

Tablo 1. R.E.N.A.L. Nefrometri Skorlama Sistemi	5
Tablo 2. Hastanın nüks profili ve tedavi etkinliği riskini dikkate alarak, lokalize RHK tedavisi sonrasında önerilen takip programı.....	8
Tablo 3. Hasta verilerinin cinsiyete göre karşılaştırılması	23
Tablo 4. Hastaların verilerinin gruplara göre karşılaştırılması	25
Tablo 5. Tümör maksimum çapı, yaş ve nefrometri skoru arasındaki Pearson korelasyon katsayıları	26
Tablo 6. Modelin düşük ve yüksek kompleksite sınıfları için sınıflandırma performans ölçütleri	30

ŞEKİLLER DİZİNİ

Şekil 1. R.E.N.A.L. nefrometri skorlamasına göre polar çizgi konumundan 1, 2 ve 3 puan alan renal kitle çizimleri	5
Şekil 2. Yapay zeka, makine öğrenmesi, derin öğrenme ve CNN ilişkisi.	9
Şekil 3. CNN Katmanları.	10
Şekil 4. Konvolüsyon filtre örnekleri	10
Şekil 5. Axial düzlemde yeniden örneklenmiş BT görüntü örnekleri.	14
Şekil 6. Geliştirilen 3D konvolüsyonel sinir ağı (3D-CNN) modelinin mimarisi.	15
Şekil 7. Eğitim süreci boyunca modelin doğruluk ve kayıp değerlerinin epoch bazlı değişimi.	17
Şekil 8. ESA(CNN) mimarisinin genel yapısı ve işlem akışı.	18
Şekil 9. Çalışmaya dahil edilen hastaların cinsiyete göre dağılımı.	22
Şekil 10. A) Tümör lateralizasyonu B) Tümörlerin anatomik yönü	24
Şekil 11. BT verilerine göre tümörlerin böbrek düzeylerine göre dağılımı.	24
Şekil 12. Modelin ROC eğrisi ve AUC değeri.	26
Şekil 13. Modelin detaylı yüzdesel ve renk kodlu karışıklık matrisi.	28
Şekil 14. Modelin sade karmaşıklık matrisi (heatmap gösterimi).....	29
Şekil 15. İstatistiksel analiz için kullanılan metrik değerleri için denklemler.	31

1. GİRİŞ VE AMAÇ

Böbrek dokusundaki hücrelerin kontrolsüz şekilde çoğalması, tümör gelişimine ve ilerleyen evrelerde kansere neden olabilmektedir. Böbrek tümörleri, ürolojik onkoloji alanında önemli bir morbidite ve mortalite kaynağı olup, son yıllarda görüntüleme tekniklerindeki gelişmelere paralel olarak daha erken evrede tanı alabilmektedir. Renal hücreli karsinom (RHK), erişkin böbrek tümörlerinin en yaygın malign formudur ve sıklıkla insidental olarak, abdominal görüntüleme sırasında tespit edilmektedir. Kontrastlı bilgisayarlı tomografi (BT), böbrek tümörlerinin tanı ve evrelemesinde altın standart görüntüleme yöntemi olarak kabul edilmekte; lezyonun boyutu, lokalizasyonu ve çevre anatomik yapılarla ilişkisini değerlendirmede temel rol oynamaktadır. BT’de kontrast madde sonrası elde edilen Hounsfield Unit (HU) artışı, malignite açısından önemli bir parametredir (1,2).

Günümüzde, özellikle nefron koruyucu cerrahinin yaygınlaşması ile birlikte, böbrek tümörlerinin anatomik kompleksitesi cerrahi planlama sürecinde belirleyici hale gelmiştir. Bu bağlamda R.E.N.A.L. nefrometri skoru gibi nefrometrik değerlendirme sistemleri, cerrahi zorluğu öngörmede ve cerrahi kararları verme aşamasında sıkça kullanılmaktadır. Ancak bu değerlendirme, zaman alıcı manuel işlemler gerektirmesi ve yorumlayıcının deneyimine bağlı değişkenlik göstermesi nedeniyle objektifliğini sınırlayabilmektedir.

Son yıllarda, yapay zeka (YZ) ve özellikle derin öğrenme algoritmaları, tıbbi görüntülerin otomatik analizi yoluyla klinik karar destek sistemlerinin geliştirilmesinde umut vadeden bir alan olarak öne çıkmaktadır. Özellikle üç boyutlu konvolüsyonel sinir ağları (3D CNN), hacimsel BT verilerinden karmaşık yapısal özellikleri öğrenerek tanıs ve prognostik sınıflandırmalarda yüksek başarı elde edebilmektedir.

Bu tez çalışmasının temel amacı, kontrastlı BT (Bilgisayarlı Tomografi) görüntüleri kullanarak, sıfırdan geliştirilen bir 3D konvolüsyonel sinir ağı (CNN) mimarisi ile böbrek tümörlerinin kompleksite düzeylerini (R.E.N.A.L. nefrometri skorlarına dayalı olarak) yüksek doğrulukla sınıflandırabilen bir model tasarlamaktır. Böylece, hekimlerin zamanını ve kaynaklarını daha verimli kullanabileceği, karar süreçlerini destekleyici, nesnel ve tekrar üretilebilir bir yapay zeka temelli sistem

oluřturulması hedeflenmektedir. Bu sistem ile daha objektif, tutarlı ve hasta yararına sonuçlar elde etmemizi saęlayacaęını savunuyoruz. Bu sayede, hastaların tedavi süreçlerinin optimizasyonunda bir artış oluşmasını hedeflemekteyiz.

Çalışma kapsamında; histopatolojik olarak malign tanısı doğrulanmış 197 hastanın kontrastlı BT görüntüleri analiz edilmiştir. Radyologlar tarafından manuel olarak oluşturulan nefrometri skorları, modelin hedef çıktısı olarak kullanılmıştır. Geliştirilen derin öğrenme modeli; eğitim ve test aşamalarında değerlendirilerek sınıflandırma başarımı duyarlılık, kesinlik, doğruluk, F1-skoru ve AUC gibi metriklerle analiz edilmiştir.

Bu doğrultuda elde edilen model çıktılarının, klinik pratikte karar verme süreçlerini destekleyebilecek düzeyde güvenilirlik göstermesi, çalışmanın özgün ve pratik katkısını ortaya koymaktadır. Bu tür bir sistemin oluşturulma süreci, modelin ayrıntıları ve çalışma prensibi tezimizde incelenecektir.

2. GENEL BİLGİLER

2.1. MALİGN BÖBREK TÜMÖRLERİ

Yetişkin yaş grubunda böbreğin malign tümörleri arasında renal hücreli karsinom (RHK), ürotelyal karsinom, lenfoma, sarkomlar ve metastatik lezyonlar yer alır. RHK, malign renal tümörlerin yaklaşık %90'ını oluşturur ve bu nedenle böbrekte saptanan şüpheli bir kitlenin öncelikle RHK olabileceği düşünülmelidir. (2–4).

RHK gelişiminde rol oynayan başlıca risk faktörleri; hipertansiyon (risk oranı x1.7), obezite (x1.7), metabolik sendrom (x1.6), sigara kullanımı, diabetes mellitus ve birinci derece akrabalarda böbrek kanseri öyküsüdür (5,6).

RHK histopatolojik olarak berrak hücreli, papiller ve kromofob tip olmak üzere üç ana alt tipe ayrılır. Renal hücreli karsinomların %5-8'i herediter formlardır. Özellikle 30'lu ve 40'lı yaşlarda görülen vakalarda Von Hippel-Lindau (VHL) ve Birt-Hogg-Dubé sendromları gibi genetik hastalıklar eşlik edebilir. Bu hasta grubunda nüks ve çoklu tümör gelişme riski yüksek olduğundan, mümkünse nefron koruyucu cerrahiler tercih edilmelidir (7–9).

RHK çoğu zaman insidental olarak görüntüleme sırasında saptanır. Klasik semptom triadı olan yan ağrısı, hematüri ve palpe edilebilen kitle günümüzde %6-10 oranında görülmekte olup, varlığı kötü prognozla ilişkilidir. Vakaların %30'unda anemi, kilo kaybı, hipertansiyon gibi paraneoplastik semptomlar görülebilir (10).

Evrelemede 2017 TNM sınıflaması kullanılır. Bu sınıflama; tümör boyutu, venöz invazyon, renal kapsül invazyonu, adrenal bez tutulumu, lenf nodu ve uzak metastaz gibi parametreleri kapsar (11,12).

Radikal nefrektomi (RN) ve parsiyel nefrektomi (PN) açık, laparoskopik veya robot yardımcı olarak gerçekleştirilebilir. Küçük ve uygun yerleşimli kitlelerde nefron koruyucu cerrahi (NKC) tercih edilmesi önerilir, çünkü karşı böbrekte gelişebilecek patolojiler göz önüne alındığında işlevsel nefronun korunması önem arz eder. Kronik böbrek yetmezliği (KBY) ile artan kardiyovasküler riskler göz önüne

alındığında PN altın standart tedavi olarak kabul edilmektedir. Uzun dönem onkolojik sonuçlar açısından RN ve PN arasında anlamlı fark bulunmamıştır (13,14).

PN sonrası böbrek fonksiyonlarının daha iyi korunmasına rağmen, bu sonucu etkileyen birçok faktör bulunmaktadır: kitle boyutu ve lokalizasyonu, iskemi tipi ve süresi, operasyon süresi, eşlik eden komorbiditeler, enükleasyon yapıp yapılmadığı, cerrahi teknik ve cerrahın deneyimi olarak sıralayabiliriz. Literatürde sıcak iskemi için kabul edilen maksimum süre 30 dakikadır (15–17).

2.2. EVRELEME VE SINIFLANDIRMA SİSTEMLERİ

2.2.1. Evreleme

Tümör, Nod, Metastaz (TNM) evreleme sistemi, renal hücreli karsinomun klinik ve bilimsel değerlendirmelerinde kullanılmak üzere önerilen bir evreleme sistemidir (18). TNM sistemi; tümör boyutu, venöz invazyon, böbrek kapsülünün tutulumu, adrenal bez invazyonu, lenf nodu (LN) durumu ve uzak metastaz varlığını dikkate almaktadır. (19).

TNM sınıflandırması, klinik kararlarda belirleyici tek kriter olarak kullanılmamalıdır. Hastanın genel durumu, eşlik eden hastalıkları ve bireysel tercihleri de tedavi planlamasında göz önünde bulundurulmalıdır. 2022 yılında Avrupa Üroloji Derneği (EAU) paneli tarafından, küçük renal kitlelerin yanı sıra lokal ileri ve metastatik hastalıklardaki güncel yönetim yaklaşımları doğrultusunda klinik bazlı yeni bir evreleme modeli önerilmiştir (20).

2.2.2. R.E.N.A.L. Nefrometri Skorlama Sistemi


R.E.N.A.L. nefrometri skorlama sistemi, 2009 yılında Kutikov ve Uzzo tarafından geliştirilmiş ve yayınlanmıştır (21). Bu sistem, parsiyel nefrektomi (PN) endikasyonlarında tümör anatomisinin değerlendirilmesine yönelik standardizasyon eksikliğini gidermek amacıyla oluşturulmuştur. R.E.N.A.L. ifadesi, her biri tümörün anatomik konumuna ilişkin beş farklı parametreyi temsil eden harflerden oluşmaktadır. Bu parametreler, tablo içerisinde ayrıntılı biçimde sunulmuştur (Tablo 1). Toplam skor hesaplandığında 4–6 puan olanlar düşük kompleksite, 7–9 puan orta kompleksite, 10–12 puan yüksek kompleksite olarak belirlenmiştir (22–24). Yüksek

kompleksiteye sahip kitlelerde parsiyel nefrektomi yerine radikal nefrektomi (RN) daha uygun bir seçenek olarak gündeme gelebilir (25).

Tablo 1. R.E.N.A.L. Nefrometri Skorlama Sistemi

R.E.N.A.L.	1 puan	2 puan	3 puan
(R) adius- Maksimum tümör çapı (cm)	≤4 cm	>4 cm ve <7 cm	≥7 cm
(E) gzofitik-Endofitik yerleşim	≥%50	≤%50	Tamamen endofitik
(N) earness- Tümörün toplayıcı sisteme veya renal sinüse yakınlığı (mm)	≥7 mm	>4 mm ve <7 mm	≤4 mm
(A) nterior-posterior yerleşim	Skor yok	Skor yok	Skor yok
(L) okalizasyon- Polar hat ile olan ilişki	Tümör polar hattın tamamen üzerinde veya altında	Tümör polar hattı geçiyor	Tümörün ≥%50'si polar hattı geçiyor veya tümör polar hattın ortasını tamamen dolduruyor

Cerrahi planlama ve sonuçların öngörülmesi açısından, hangi parametreden yüksek puan alındığı, toplam skordan daha belirleyici olabilmektedir. Bu bağlamda, özellikle endofitik özellik, toplayıcı sisteme yakınlığı ve polar çizgi ilişkisi gibi faktörlerin öne çıktığı vakalar, daha dikkatli değerlendirilmelidir (Şekil 1).



Şekil 1. R.E.N.A.L. nefrometri skorlamasına göre polar çizgi konumundan 1, 2 ve 3 puan alan renal kitle çizimleri (Üst ve alttaki çizgiler polar çizgi sınırlarını, ortadaki kesik çizgi ise orta hattı gösterir) (21).

2.3. GÖRÜNTÜLEME

Kontrastlı BT incelemelerinde arteriyel faz, venöz faz (kortikomedüller faz), nefrogram faz incelenmektedir (26). Kontrastlı BT, karşı böbreğin durumu, tümörün yayılımı, venöz invazyon, lenf nodu büyümesi ve adrenal ya da diğer organ tutulumu hakkında bilgi sağlar ve hem tanı hem evrelemede kapsamlı bilgi sağlayan başlıca görüntüleme yöntemlerinden biridir (27,28). Gerekli durumlarda, BT anjiyografi ile renal damar yapısı detaylı olarak değerlendirilebilir (29,30).

2.4. LOKALİZE RENAL HÜCRELİ KANSERİN TEDAVİSİ

Günümüzde renal hücreli karsinom (RHK) olgularının büyük bir kısmı tanı anında T1 ve T2 evrelerinde, yani lokalize hastalık aşamasında saptanabilmektedir. Bu evrede başlıca tedavi seçenekleri cerrahi müdahale, termal ablasyon yöntemleri ve aktif izlem stratejileridir (31). Lokalize RHK için cerrahi tedavi, mevcut literatüre göre en yüksek düzeyde kanıtla desteklenen ve küratif potansiyeli bulunan tek tedavi seçeneği olarak kabul edilmektedir (7).

Renal hücreli karsinomun (RHK) lokalize evrelerinde cerrahi tedavide önemli bir dönüm noktası, Robson ve arkadaşlarının 1969 tarihli çalışmasıyla yaşanmıştır ve radikal nefrektomi, böbrek kanserinde standart tedavi yöntemi haline gelmiştir (32).

Radikal nefrektomi sırasında rutin lenf nodu diseksiyonu (LND) uygulanması halen tartışmalıdır. RHK olgularında lenf nodu metastazı oranı tüm evrelerde %13–21 iken, düşük evrelerde bu oran %2–9’a gerilemektedir (33,34). Bazı çalışmalar, genişletilmiş LND’nin sağkalım üzerine olumlu etkileri olabileceğini bildirmektedir (35–37). Bu doğrultuda, preoperatif görüntüleme veya peroperatif değerlendirme ile şüpheli bulunan lenf nodlarının çıkarılması uygun görülmektedir.

Laparoskopik radikal nefrektomi ilk kez 1990 yılında Clayman ve arkadaşları tarafından gerçekleştirilmiştir (38). Laparoskopik cerrahi, daha kısa hastanede kalış süresi, daha az kan kaybı ve daha düşük analjezik ihtiyacı gibi avantajlar sunmaktadır. Bu nedenle günümüzde radikal nefrektomi için standart cerrahi yaklaşım haline gelmiştir (39–41).

Açık radikal nefrektomide cerrahi yaklaşımlar arasında flank, anterior, torakoabdominal ve dorsal lumbotomi teknikleri yer alır. Cerrahi yöntemin seçimi; preoperatif görüntüleme bulguları, önceki cerrahiler, hastanın anatomik özellikleri ve anesteziye ilişkin kısıtlamalar gibi çeşitli faktörlere bağlıdır (42).

Parsiyel nefrektomi (PN), ilk kez 1890 yılında Czerny tarafından tanımlanmıştır (43). Bu cerrahinin temel amacı, tümörün tamamen çıkarılmasıyla birlikte mümkün olan en fazla sağlam böbrek dokusunun korunmasıdır. PN özellikle, kalıtsal böbrek tümörü sendromlarında, soliter böbrek varlığında veya diğer böbreğin fonksiyonunu etkileyebilecek sistemik hastalıkların bulunduğu durumlarda öncelikli olarak tercih edilmelidir (44).

Kronik böbrek hastalığı (KBH) ile artmış kardiyovasküler risk, hastaneye yatış oranı ve mortalite arasındaki ilişki, böbrek fonksiyonunu koruyucu cerrahilerin önemini ortaya koymuştur. PN sonrası uzun dönem onkolojik sonuçlar RN ile benzerken, böbrek fonksiyonunun daha iyi korunduğu gösterilmiştir (17,45,46).

PN açık, laparoskopik (LPN) veya robotik (RPN) yöntemlerle uygulanabilmektedir. Geçmişte açık cerrahi standart yaklaşım olarak benimsenmiş olsa da, son yıllarda minimal invaziv yöntemlerin kullanımı yaygınlaşmıştır (47). Mevcut kanıtlar, onkolojik sonuçlar açısından yöntemler arasında belirgin bir fark olmadığını göstermektedir (48).

2.5. TAKİP

RHK sonrası takip stratejileri konusunda net bir görüş birliği bulunmamaktadır (49). Bireyselleştirilmiş bir izlem yaklaşımı gerekmektedir. Takip yalnızca görüntüleme ile sınırlı olmayıp; böbrek fonksiyonları, kardiyovasküler olaylar ve son dönem böbrek hastalığı gibi uzun dönem sonuçların izlenmesi açısından da önem taşır (50).

Parsiyel nefrektomi sonrası lokal nüks nadir görülse de, cerrahi genellikle en etkili tedavi yöntemi olduğundan erken tanı kritiktir (51). Karşı böbrekte nüks ise %1–2 oranında ve genellikle geç dönemde ortaya çıkar (52). Takip süreci, lokal ya da sistemik nükslerin erken tanınmasını sağlayarak cerrahi şansı artırabilir. Düşük

tümör yükünde erken saptama, sistemik tedavinin etkinliğini de artırabilir (53). Aşağıdaki tabloda risk profiline göre takip periyodu ve şekli belirtilmiştir.

Tablo 2. Hastanın nüks profili ve tedavi etkinliği riskini (uzman görüşüne dayalı olarak) dikkate alarak, lokalize RHK tedavisi sonrasında önerilen takip programı (53)

Risk Profili	Tanım	3. ay	6. ay	12. ay	18. ay	24. ay	30. ay	36. ay	>36. ay	>60. ay
Düşük tekrarlama riski	bhRHK: Leibovich Skoru 0–2 bhRHK olmayanlar: Düşük UISS risk grubu: Düşük	-	BT	-	BT	-	BT	-	Her iki yılda bir BT	-
Orta derecede tekrarlama riski	bhRHK: Leibovich Skoru 3–5 bhRHK olmayanlar: Orta UISS risk grubu: Orta	-	BT	BT	-	BT	-	BT	Yılda bir BT	Her iki yılda bir BT
Yüksek tekrarlama riski	bhRHK: Leibovich Skoru ≥ 6 bhRHK olmayanlar: Yüksek UISS risk grubu: Yüksek	BT	BT	BT	BT	BT	-	BT	Yılda bir BT	Her iki yılda bir BT


* Tablodaki bilgisayarlı tomografi hem göğüs hem de karın bölgesinin görüntülenmesini ifade etmektedir. Alternatif olarak, BT taraması yerine abdomen MRG yapılabilir.

2.6. YAPAY ZEKA (ARTİFİCİAL INTELLIGENCE, YZ, AI)

2.6.1. Derin Öğrenme (Deep Learning, DL)

Derin öğrenme, makine öğrenmesi kapsamında yer alan ve çok katmanlı yapay sinir ağlarının kullanımına dayanan bir yöntemdir. Kavramsal olarak hiyerarşik yapı Şekil 2’de gösterilmiştir.

Derin öğrenme modelleri, katmanların birbirine bağlı şekilde çalıştığı yapılarla oluşturulur. Her katman, önceki katmanın çıktısını girdi olarak alır ve bu süreç ağ boyunca sıralı olarak ilerler. Bu yapı, modelin veriyi aşamalı biçimde daha soyut düzeylerde temsil etmesini sağlar. Derin öğrenme algoritmaları; görüntü işleme, ses tanıma ve doğal dil işleme gibi çeşitli alanlarda yüksek başarıyla uygulanmakta, özellikle büyük ve karmaşık veri setlerinin analizinde önemli avantajlar sunmaktadır (54,55).




Şekil 2. Yapay zeka, makine öğrenmesi, derin öğrenme ve CNN ilişkisi.

2.6.2. Konvolüsyonel Nöral Ağlar (CNN; Convolutional Neural Network, Evrişimli Sinir Ağları)

Konvolüsyonel sinir ağları (CNN), çok katmanlı yapay sinir ağlarının, özellikle görüntü tanıma ve sınıflandırma gibi görsel görevler için geliştirilmiş özel bir türüdür. Bu ağlar, insan beynindeki görsel korteksin bilgi işleme yapısına benzer şekilde çalışır. CNN'lerin temelini oluşturan “konvolüsyon” işlemi, klasik matris çarpımından farklı, özel bir matematiksel işlemidir. Konvolüsyon katmanları, giriş verisi üzerinde öznitelik haritaları (feature maps) oluşturarak yerel örüntüleri tanımayı ve bu bilgileri daha üst düzey temsillere dönüştürmeyi sağlar. (56).


2.6.3. Konvolüsyonel Nöral Ağların Mimarisi

CNN katmanları şu şekildedir (56,57) (Şekil 3):



Şekil 3. CNN Katmanları.

Giriş katmanı; Verilerin modele dahil edildiği noktayı temsil eder. Görüntü işleme uygulamalarında bu katman, modele sunulan görsel verinin boyutlarını tanımlar. CNN mimarisinin temel yapı taşı olan konvolüsyon katmanı, görsel verilerdeki belirgin örüntüleri ve öznitelikleri algılamakla sorumludur. Bu katman, giriş verisi üzerinde konvolüsyon çekirdekleri yani filtreler kullanarak öznitelik haritaları (feature maps) üretir (Şekil 4).



Şekil 4. Konvolüsyon filtre örnekleri (58).

Aktivasyon katmanı, genellikle konvolüsyon katmanlarının hemen sonrasında yer alır ve modelin doğrusal olmayan ilişkileri öğrenebilmesini sağlamak amacıyla kullanılır. Havuzlama katmanı, modelin parametre sayısını azaltmak ve hesaplama yükünü düşürmek amacıyla kullanılmaktadır. Düzleştirme katmanı, konvolüsyon ve havuzlama işlemlerinden elde edilen çok boyutlu öznitelik haritalarını tek boyutlu

vektörlere dönüştürerek, ağıın son bölümünde yer alan tam bağı katmana uygun bir giriş yapısı sağlar. Tam bağı katman, genellikle CNN mimarisinin son bölümünü oluşturur ve tüm nöronların birbirine bağı olduğı klasik yapay sinir ağı katmanıdır.

2.6.4. 3D Konvolüsyonel Sinir Ağı (3D-CNN)

3D konvolüsyon, ardışık olarak birleştirilmiş çoklu görüntü dilimlerinden oluşan bir küp üzerine üç boyutlu çekirdeklerin uygulanmasıyla gerçekleştirilir. Geleneksel CNN'ler genellikle RGB görüntüler (3 kanal) için geliştirilmiştir. 3D CNN'lerin amacı ise bir video ya da görüntü dilimlerinden oluşan bir veri kümesini girdi olarak alıp buradan anlamlı özellikler çıkarmaktır.

Klasik CNN'ler tek bir görüntünün görsel özelliklerini çıkararak bunları düşük seviyeli bir vektörel temsil haline getirirken, 3D CNN'ler birden fazla görüntüden oluşan bir dizi üzerinden bu işlemi gerçekleştirir. Böylece, bir görüntü dizisine ait düşük seviyeli bir temsil oluşturulur ve bu temsil, ilgili video ya da görüntü kümesinin doğru etiketlenmesinde kullanılır.

Bu özellikleri elde edebilmek için 3D konvolüsyon işlemleri kullanılır. Bu çalışmada, girdi olarak bilgisayarlı tomografi (BT) görüntülerini alan bir 3D konvolüsyonel sinir ağı modeli geliştirilmiştir.

2.6.5. Nöral Ağların Eğitiminde Hiperparametreler

Makine ve derin öğrenme modellerinde, öğrenme süreci model parametreleri ve hiperparametrelerden oluşur. Model parametreleri, ağ eğitimi sırasında otomatik olarak güncellenen ve modelin verilerden öğrendiğı değişkenlerdir. Bunlar, özellikle ağırlıklar ve sapma terimleri olarak tanımlanabilir ve modelin çıktısını doğrudan etkiler (55). Öte yandan, hiperparametreler, model eğitimi başlamadan önce araştırmacı ya da uygulayıcı tarafından manuel olarak belirlenir. Bu parametreler, öğrenme algoritmasının nasıl çalışacağını belirleyen dışsal kontrol değişkenleridir. Modelin genel başarımı üzerinde dolaylı fakat kritik bir etkiye sahiptirler. Uygun hiperparametre seçimi, modelin hem doğruluğunu hem de eğitim verilerine karşı genel uyum yeteneğini artırabilir (55,59). Sık kullanılan hiperparametreler öğrenme hızı, epoch (eğitim tur sayısı), batch boyutu (veri grubu büyüklüğü), dropout (seyreltme) olarak sıralanabilir.

3. GEREÇ VE YÖNTEM

3.1. ÇALIŞMA GRUBU

Tezimizde bilgisayarlı tomografide malign böbrek tümörü tanısı ile nefrektomi operasyonu geçirmiş hastalar seçilmiştir. Araştırmaya toplamda 197 hastaya ait kontrastlı bilgisayarlı tomografi verisi dahil edilmiştir.

Dahil edilme kriterleri;

1. 18 yaşından büyük olması ve 90 yaşından küçük olması
2. Bilgisayarlı tomografi çekilmiş ve böbrek tümörü tanısı almış olan hastalar
3. Bilgisayarlı tomografi görüntüleri net ve anlaşılır olan hastalar
4. Hastaların parsiyel veya total nefrektomi operasyonu geçirmiş olması
5. Hastaların böbrek tümörü tanısının histopatolojik olarak kesinleşmiş olması

Dışlama kriterleri olarak ise;

1. Histopatolojik olarak benign tümör tanısı almış olanlar
2. Bilgisayarlı tomografi görüntüsü olmayan veya düşük çözünürlüklü olan hastalar
3. Böbrekteki tümörün başka bir organ kaynaklı metastaz olduğu tespit edilen hastalar
4. BT görüntüsü çekilmeden önce kemoterapi veya radyoterapi almış olan hastalar
5. Demografik, patolojik ya da operasyonel verileri eksik olan hastalar
6. Aynı hastanın birden fazla BT görüntüsü mevcutsa, kötü veya operasyon süresine uzak olan görüntüler
7. Standardizasyonu önemli miktarda bozabilecek özellikler taşıyan hastalar çalışma dışı bırakılmıştır.

3.2. VERİ TOPLAMA

Çalışmada kullanılan veriler, 01.01.2019 - 01.06.2025 tarihleri arasında hastanemizdeki Cerrahi Tıp bilimleri Üroloji Anabilim dalı Üroloji Kliniği'nden toplanmıştır. Hastaların yaşı, cinsiyeti, tümörün böbrekteki konumu, tümörün hangi böbrekte olduğu, R.E.N.A.L. nefrometri skorları kaydedilmiştir. Görüntüleme

işlemleri, hastanemizde bulunan Toshiba Aquilion Prime 160 Kesit ve Siemens SOMATOM Force 1024 Kesit BT cihazları kullanılarak yapılmıştır. BT çekimleri, kontrast madde enjeksiyonu sonrası portal fazda yapılmıştır. Sistemdeki kontrastlı abdomen BT görüntülerinin hepsi DICOM formatında elde edilmiştir. Hasta bilgileri, kimlik numarası, protokol numarası gibi verileri içeren kesitler etik ilkeler kapsamında görüntüden silinerek veri seti anonimleştirilmiştir.

Bilgisayarlı tomografide elde edilen veriler


1. Renal tümörün kontrast tutulum paterni ve çapı
2. Renal tümörün egzofitik / endofitik olup olmadığı
3. Renal tümörün sınırının toplayıcı sisteme olan uzaklığı
4. Renal tümörün anterior veya posterior yerleşimi
5. Renal tümörün polar çizgilere olan uzaklığı

Hastaların görüntülerindeki tümörler kompleksite açısından iki gruba ayrılmıştır. Gruplar oluşturulurken R.E.N.A.L. nefrometri skorlamalarına göre düşük ve yüksek kompleksite şeklinde ayrılmıştır. Skorlamalar deneyimli ve alanında yetkin radyolog tarafından yapılmıştır. R.E.N.A.L. nefrometri skorlaması yapılan hastalardan skoru 8 ve altında olanlar düşük kompleksite, 9 ve üstü olanlar ise yüksek kompleksite olarak kabul edilmiştir. Orta kompleksite grubu veri sayısının azlığı nedeniyle modelin verimli çalışmasını bozacağı için bu şekilde değerlendirilmiştir.

3.3. VERİ HAZIRLAMA VE ÖN İŞLEME

Bu bölümde, tümör kompleksitesi tahmini görevinde kullanılan yöntemin temel bileşenleri ve algoritmik adımları açıklanmaktadır. Amacımız, $f(X) \in \{0,1\}$ şeklinde ayırım yapabilen bir sınıflandırma fonksiyonu öğrenmektir; burada 1 yüksek tümör kompleksitesini, 0 ise düşük kompleksiteyi temsil etmektedir. X , $W \times H \times D$ boyutlarında bir BT görüntü hacmini ifade eder; burada W , H ve D sırasıyla görüntünün genişliğini, yüksekliğini ve derinliğini temsil etmektedir. Bu çalışmada işlenen tüm kontrastlı abdomen BT görüntüleri, analiz sürecinde tutarlılığı sağlamak ve hesaplama verimliliğini artırmak amacıyla 3D Slicer yazılımı aracılığıyla $128 \times 128 \times 64$ voksel boyutuna yeniden örneklendirilmiştir. Görsel verilerin bu şekilde standart boyutlara getirilmesi, derin öğrenme modeline giriş için gerekli olan

temel ön işleme adımlarından biridir. Yeniden örnekleme sürecinde, tümör içeren böbrek dokusu sınırlı bir hacim içerecek şekilde manuel veya yarı otomatik tanımlı bounding box (sınır kutusu) yöntemi uygulanmıştır. Bu yaklaşım, görüntünün yalnızca ilgilenilen bölgesine (region of interest, ROI) odaklanılarak, modelin dikkatini dağıtacak gereksiz çevresel dokulardan arındırılmakta, homojen bir veri temsili elde edilmesini sağlamaktadır. Aşağıdaki şekilde bu kesitin örnekleri yer almaktadır.



Şekil 5. Axial düzlemde yeniden örneklenmiş BT görüntü örnekleri.

Çalışmada kullanılan BT görüntüleri, DICOM formatından NIFTI (ni.gz) dosya biçimine dönüştürülmüştür. Bu görüntüler Hounsfield Unit (HU) değerleri içeren hacimsel medikal verilerden oluşmaktadır. Görüntülerin yoğunluk aralığını normalize etmek amacıyla, tüm hacimsel veriler -1000 HU ile $+400$ HU arasında sınırlandırılmıştır. Bu işlem sonrasında, değerler bu aralıkta yeniden ölçeklendirilerek $0-1$ aralığına normalize edilmiştir. Bu yoğunluk normalizasyonu sayesinde, modelin daha stabil ve hızlı öğrenmesi sağlanmıştır. Normalize edilen

veriler float32 veri tipine dönüştürülerek derin öğrenme modeline giriş olarak verilmiştir.

3.4. DERİN ÖĞRENME MODELİ MİMARİSİ (3D CNN)

Modelin amacı, BT görüntülerinden düşük ve yüksek kompleksiteli renal tümörleri sınıflandırabilecek özellikleri otomatik olarak çıkartmaktır. Aşağıda buradaki modelin yapısı ve katmanları özetlenmiştir.

Model: "3dcnn"		
Layer (type)	Output Shape	Param #
input_10 (InputLayer)	[(None, 128, 128, 64, 1)]	0
conv3d_36 (Conv3D)	(None, 126, 126, 62, 64)	1792
max_pooling3d_36 (MaxPooling3D)	(None, 63, 63, 31, 64)	0
batch_normalization_36 (BatchNormalization)	(None, 63, 63, 31, 64)	256
conv3d_37 (Conv3D)	(None, 61, 61, 29, 64)	110656
max_pooling3d_37 (MaxPooling3D)	(None, 30, 30, 14, 64)	0
batch_normalization_37 (BatchNormalization)	(None, 30, 30, 14, 64)	256
conv3d_38 (Conv3D)	(None, 28, 28, 12, 128)	221312
max_pooling3d_38 (MaxPooling3D)	(None, 14, 14, 6, 128)	0
batch_normalization_38 (BatchNormalization)	(None, 14, 14, 6, 128)	512
conv3d_39 (Conv3D)	(None, 12, 12, 4, 256)	884992
max_pooling3d_39 (MaxPooling3D)	(None, 6, 6, 2, 256)	0
batch_normalization_39 (BatchNormalization)	(None, 6, 6, 2, 256)	1024
global_average_pooling3d_9 (GlobalAveragePooling3D)	(None, 256)	0
dense_18 (Dense)	(None, 512)	131584
dropout_9 (Dropout)	(None, 512)	0
dense_19 (Dense)	(None, 1)	513
Total params: 1,352,897		
Trainable params: 1,351,873		
Non-trainable params: 1,024		

Şekil 6. Geliştirilen 3D konvolüsyonel sinir ağı (3D-CNN) modelinin mimarisi.

Modelin giriş boyutu (128, 128, 64, 1) olup; bu yapı, 128x128 piksel çözünürlüğe ve 64 dilime sahip, tek kanallı üç boyutlu BT görüntü hacmini temsil etmektedir. Model mimarisi, dört ardışık konvolüsyon bloğundan oluşmaktadır. Her bir blok aşağıdaki üç temel bileşeni içermektedir:

1. 3D Konvolüsyon (Conv3D) Katmanı: Görüntü hacminden uzamsal özelliklerin çıkarılmasını sağlar.
2. 3D Maksimum Havuzlama (MaxPooling3D) Katmanı: Hacim boyutlarını azaltarak daha soyut ve özet özelliklerin elde edilmesine olanak tanır.
3. Batch Normalization Katmanı: Ağırlıkların dağılımını normalize ederek modelin daha hızlı ve kararlı öğrenmesini sağlar.

İlk konvolüsyon bloğunda 64 filtre kullanılmış olup, bu sayı her blokta sırasıyla $64 \rightarrow 128 \rightarrow 256$ şeklinde artırılmıştır. Böylece modelin daha karmaşık ve derin özellikleri öğrenebilme kapasitesi geliştirilmiştir. Havuzlama katmanları aracılığıyla her blokta hacim boyutları azaltılarak, bilgi yoğunluğu artırılmıştır.

Konvolüsyonel blokların ardından, modelde Global Average Pooling 3D katmanı kullanılmıştır. Bu katman, her bir 3D özellik haritasını ortalayarak sabit boyutlu bir vektöre dönüştürür. Elde edilen bu özellik vektörü, aşağıda belirtilen tam bağlantılı katmanlara iletilir:


- Dense (512): 512 nörondan oluşan bu katmanda, çıkarılan özellikler işlenir.
- Dropout (%50): %50 oranında rastgele nöron devre dışı bırakılarak aşırı uyum (overfitting) riski azaltılır.
- Dense (1): Çıkış katmanıdır. Tek nöron içerir ve sigmoid aktivasyon fonksiyonu ile ikili (binary) sınıflandırma gerçekleştirir.

Modelin toplam parametre sayısı 1.352.897'dir. Bu parametrelerin 1.351.873'ü eğitilebilir olup, 1.024'ü sabit parametrelerdir.

Bu yapı, BT görüntülerindeki tümör dokularını ayrıntılı biçimde analiz ederek, düşük ve yüksek kompleksite düzeylerini başarılı şekilde ayırt edebilen etkili bir sınıflandırma modeli sunmaktadır.

Bu çalışmada kullanılan evrişimli sinir ağı yöntemi bir derin öğrenme algoritması olup özellikli görüntü verileriyle çalışmaktadır. Kendi içinde binlerce kez eğitilmiş hazır paket katman yapılarına sahip transfer fonksiyonları bu çalışmada kullanılmamıştır. Bu çalışmada kullanılan ağ mimarisi tamamen malign böbrek tümörlerinde kompleksite düzeyini belirleyerek nefrektomi karar süreçlerinde kullanılmak üzere sıfırdan geliştirilmiştir.

3.5. MODEL EĞİTİMİ VE ÖĞRENME SÜRECİ




Şekil 7. Eğitim süreci boyunca modelin doğruluk ve kayıp değerlerinin epoch bazlı değişimi.

Oluşturduğumuz iki gruptan gelen veriler %85 eğitim, %15 validasyon verisi olarak bölünmüştür. Ardından her sınıf için elde edilen doğruluk değerleri belirtilip veri seti ile eğitilmiş her ağ model olarak kaydedilmiştir. Modelin eğitimi için Adam optimizasyon algoritması kullanılmıştır. Hiperparametrelerin belirlenmesi için deneysel denemeler gerçekleştirilmiş olup, en verimli sonuçlar başlangıç öğrenme oranı 5×10^{-6} olarak belirlendiğinde elde edilmiştir. Eğitim süreci, 500 epoch boyunca devam ettirilmiş ve modelin öğrenme performansı bu doğrultuda optimize edilmiştir. Modelin eğitimi sırasında doğruluk ve kayıp değerlerinin değişimi Şekil 7'de gösterilmektedir. Sol tarafta yer alan grafik, eğitim ve doğrulama verisi üzerindeki doğruluk değerlerinin epoch sayısına göre değişimini göstermektedir. Eğitim verisi doğruluğu (mavi çizgi) eğitim süreci boyunca istikrarlı bir şekilde artış göstermektedir ve yaklaşık 0.92 civarına kadar yükselmiştir. Bu durum, modelin eğitim verisini başarılı şekilde öğrendiğini göstermektedir. Doğrulama verisine ait doğruluk değerleri (turuncu çizgi) ise erken epoch'larda hızlı bir yükseliş sergilemiş, ancak sonrasında dalgalı bir seyir izlemiştir. Yaklaşık 0.73–0.78 bandında stabil hale gelmiştir. Eğitim ve doğrulama doğrulukları arasındaki bu fark, modelin belirli

ölçüde aşırı öğrenme yani overfitting eğilimi gösterdiğini düşündürebilir. Ancak doğrulama doğruluğu da genel olarak kabul edilebilir düzeydedir.

Sağdaki kayıp eğrisi grafiği, modelin eğitim ve doğrulama kümelerindeki kayıp değerlerinin epoch'lara göre değişimini göstermektedir. Eğitim kaybı (mavi çizgi) zamanla düzenli şekilde azalarak modelin öğrenmeye devam ettiğini göstermektedir. Doğrulama kaybı (turuncu çizgi) ise erken dönemde hızlı bir düşüş gösterip daha sonra sabitlenmiştir. Doğrulama kaybının eğitim kaybına göre daha yüksek seyretmesi, modelin belirli ölçüde aşırı öğrenme (overfitting) eğilimi göstermiş olabileceğini düşündürmektedir. Ancak bu fark, doğrulama performansının genel olarak stabil kalması nedeniyle kritik düzeyde değildir ve modelin genelleme yeteneğini koruduğu söylenebilir.

3.6. MODEL MİMARİSİ VE ÖZELLİK ÖĞRENME SÜRECİ



Şekil 8. ESA(CNN) mimarisinin genel yapısı ve işlem akışı.

Bu çalışmada, girdi verileri, radyologlar tarafından tümörün bulunduğu bölgeler manuel olarak işaretlenmiş görüntülerden oluşturulmuş ve $128 \times 128 \times 64$ boyutlarında hacimsel yapılar şeklinde modele verilmiştir. Bu yapı, hem uzamsal hem de hacimsel bilgilerin derin katmanlar aracılığıyla öğrenilmesine olanak tanımaktadır.

Şekil 8’de de görüldüğü üzere model; dört adet üç boyutlu konvolüsyonel katmandan (Conv3D) oluşmaktadır. İlk iki katmanda 64, sonraki katmanlarda ise sırasıyla 128 ve 256 filtre kullanılmıştır. Her konvolüsyon katmanından sonra $2 \times 2 \times 2$ boyutlu maks-pooling (MaxPool3D) işlemi uygulanarak modelin öğrenme karmaşıklığı dengelenmiştir. Tüm bu katmanlar ReLU aktivasyon fonksiyonu ve batch normalization ile desteklenmiştir.

Öznitelik çıkarım süreci sonunda elde edilen çıktılar düzleştirilmiş ve 512 nöronlu bir tam bağlantılı katmana aktarılmıştır. Bu katmandan sonra %50 oranında dropout uygulanarak aşırı öğrenmenin önüne geçilmiştir. Son olarak, sigmoid aktivasyon fonksiyonuna sahip 2 nöronlu çıkış katmanı kullanılarak ikili sınıflandırma yapılmıştır. Bu yapı, tümörlerin düşük ve yüksek kompleksiteli olarak sınıflandırılmasını sağlamaktadır.

3.7. PERFORMANS ÖLÇÜTLERİ

Duyarlılık (Sensitivity): Modelin bir sınıftaki gerçek pozitifleri ne kadar doğru şekilde yakalayabildiğini gösterir.

Kesinlik (Precision): Modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu belirtir.

F1 Skoru: Kesinlik ve duyarlılığın harmonik ortalamasıdır. Özellikle dengesiz veri setlerinde kullanılır.

Doğruluk (Accuracy): Tüm sınıflandırmaların ne kadarının doğru olduğunu gösterir. Modelin genel başarısını ortaya koyar.

Karmaşıklık Matrisi (Confusion Matrix): Her bir sınıfın doğru ve yanlış sınıflandırma sayısını gösteren tablodur.

3.8. KULLANILAN YAZILIMLAR VE ARAÇLAR

Verilerin elde edilmesinde ve analizinde yapay zeka ve derin öğrenme konusunda en fazla tercih edilen yazılım dili olan Python (v3.12.7) kullanılmıştır. Analiz sürecinde python diline ait açık kaynak kodlu; Pandas (v2.2.3), Numpy (v2.2.0), Scikit-learn (v1.6.0), Optuna (v 4.1.0), joblib (v1.4.2), google.colab (v1.0.0), TensorFlow (v2.18.0), Keras (v3.7.0), pymupdf (v1.25.1) ve matplotlib (v3.10.0), SimpleITK (2.5.2), nibabel (5.3.2), scipy (1.16.1) kütüphaneleri kullanılmıştır. Donanım olarak Google Colab üzerinden 40 gb ram desteğine sahip Nvidia A100 ekran kartı, 2 adet vCPU çekirdeğine sahip Intel Xeon işlemci ve 52 GB bellek kullanılmıştır.

3.9. İSTATİSTİKSEL ANALİZ

Sürekli değişkenlerin tanımlayıcı istatistiklerinde ortalama, standart sapma; kategorik değişkenlerin tanımlanmasında ise frekans (n) ve yüzde (%) değerleri verilmiştir. Değişkenlerin normallik varsayımları Kolmogorov Smirnov testi ve skewness kurtosis katsayıları ile incelenmiştir.

Çalışmadaki sürekli değişkenler normallik varsayımını karşılamıştır. İncelemelerde ikili gruplarda Bağımsız Örneklemelerde t test (Independent samples t test) kullanılmıştır. Kategorik değişkenler arasındaki ilişkiler Ki kare testi ile incelenmiştir.

Sürekli değişkenler arasındaki doğrusal ilişkiyi belirlemek amacıyla Pearson korelasyon analizi uygulanmıştır. Bütün analizlerde IBM SPSS.25 programı kullanılmış ve anlamlılık düzeyi olarak $p < 0.05$ değeri kabul edilmiştir.

3.10. GÜÇLÜKLER VE SINIRLAMALAR

Bu çalışmada elde edilen bulgular literatüre çok değerli katkılar sunsa da, bazı metodolojik ve teknik sınırlamalar göz önünde bulundurulmalıdır. Öncelikle, çalışmanın retrospektif tasarıma sahip olması nedeniyle hasta seçimi ve görüntüleme verilerinin kontrolü sınırlı kalmıştır. Araştırmada kullanılan tüm kontrastlı bilgisayarlı tomografi (BT) verilerinin, tek bir merkezden ve aynı iki görüntüleme cihazından elde edilmesi görüntü kalitesinde homojenlik sağlasa da, farklı cihazlar ve merkezler arası çeşitliliği dışladığı için sonuçların genellenebilirliğini azaltmaktadır.

Ayrıca, çalışmaya yalnızca nefrektomi operasyonu geçirmiş ve histopatolojik olarak malign böbrek tümörü tanısı doğrulanmış hastalar dahil edilmiştir. Bu seçici örneklem yapısı, modelin benign vakalara veya önceden tedavi almış hastalara uygulanabilirliğini sınırlamaktadır. Bir diğer zorluk, bazı hastalara ait klinik veya patolojik verilerin eksik ya da standart dışı olması nedeniyle dışlanmak zorunda kalınmasıdır. Bu da çalışma popülasyonunun daha da daralmasına yol açmıştır.

Veri etiketleme sürecinde, sınıflandırma ve skoreleme işlemleri için uzman görüşü gerektirmesi, zamansal ve insan kaynağı açısından ek yük oluşturmuştur.

Yapay zekâ temelli modellerin eğitildiği örnek sayısı her ne kadar klinik açıdan anlamlı olsa da ($n=197$), daha büyük ve çok merkezli veri setleri ile karşılaştırıldığında sınırlı kalmaktadır. Bu durum, modelin farklı popülasyonlar üzerindeki performansını değerlendirme imkânını kısıtlamaktadır ve ayrıca bu durum modelin iç geçerliği açısından avantaj sağlarken; dış geçerlik, yani farklı hasta popülasyonları, cihaz markaları ve çekim protokollerinde gösterdiği performans hakkında sınırlı bilgi sunmaktadır.

Gelecekteki çalışmalar, bu modelin çok merkezli, farklı etnik ve demografik özelliklere sahip hasta gruplarında ve çeşitli BT cihazları ile elde edilmiş veriler üzerinde test edilmesi ile zenginleştirilmelidir. Böylece modelin genellenebilirliği daha yüksek düzeyde değerlendirilebilir. Özellikle farklı çözünürlükte görüntüleme cihazlarında eğitilen modellerle çapraz doğrulama yapılması, farklı merkezlerden gelen etiketli verilerle dış test yapılması, farklı kontrast protokolleri veya çekim parametrelerinin etkisinin değerlendirilmesi, prospektif veriyle gerçek zamanlı klinik doğrulama gibi stratejiler, bu yapay zekâ modelinin klinik alanda daha geniş çapta geçerliliğe sahip bir araç haline gelmesini sağlayabilir.

3.11. ETİK VE YASAL UYGULAMALAR


Bu çalışma için “Afyonkarahisar Sağlık Bilimleri Üniversitesi Müdahale Olmayan Bilimsel Araştırmalar Etik Kurulu” tarafından 06/12/2024 tarihinde etik kurul onayı alınmıştır (Toplantı no: 2024/10, Karar no: 469).

Veri toplama ve analiz aşamasında hastaların kimlik bilgilerinin gizliliği ve verilerin anonimliği uygun yöntemlerle sağlanmıştır.

4. BULGULAR

4.1. DEMOGRAFİK VE KLİNİK ÖZELLİKLER

Afyonkarahisar Sağlık Bilimleri Üniversitesi Araştırma ve Uygulama Hastanesi'nde 01.01.2019-01.06.2025 tarihleri arasında çekilen kontrastlı bilgisayarlı tomografi sonrası böbrek tümörü tanısıyla nefrektomi gerçekleştirilmiş 197 hastanın kontrastlı bilgisayarlı tomografi verileri incelenmiştir. BT verileri elde edilmiş olan hastaların 80'i kadın (%40,6), 117'si erkek (%59,4) hastaya aitti (Şekil 18).



Şekil 9. Çalışmaya dahil edilen hastaların cinsiyete göre dağılımı.

Bütün hastaların yaş ortalaması 61.11 ± 11.46 yıl, tümör çapları ortalaması 5.40 ± 3.04 cm ve nefrometri skoru ortalaması 7.98 ± 2.17 idi.


Tablo 3. Hasta verilerinin cinsiyete göre karşılaştırılması

		Kadın n=80	Erkek n=117	p
Yaş		60.83±11.70	61.30±11.33	0.776*
Tümör Maksimum Çapı		5.15±2.79	5.58±3.19	0.326*
Nefrometri Skoru		7.91±2.12	8.03±2.22	0.721*
Lateralite n(%)	Sağ	43(%53.8)	60(%51.3)	0.845**
	Sol	37(%46.3)	57(%48.7)	
Tümör Yönü n(%)	Anterior	35(%43.8)	38(%32.5)	0.106**
	Posterior	34(%42.5)	50(%42.7)	
	X	11(%13.8)	29(%24.8)	
Tümör Düzeyi	Üst pol	10(%12.5)	26(%22.2)	0.369**
	Orta pol	30(%37.5)	41(%35.0)	
	Alt pol	27(%33.8)	35(%29.9)	
	Birden fazla pol	13(%16.3)	15(%12.8)	

*: Student T testi, **: Pearson Ki Kare Analizi, X: Yönü tanımlanamayan ya da atipik şekilde yerleşimli


4.2. TÜMÖR ÖZELLİKLERİNE AİT BULGULAR

Tümör lateralizasyonu açısından incelendiğinde 103 (%52.3) hastanın sağda, 94 (%47.7) hastanın solda yerleşim göstermekteydi (Şekil 10A). Ayrıca tümör yönü açısından değerlendirildiğinde 73 (%37.1) hastada anterior, 84 (%42.6) hastada posterior ve 40 (%20.3) hastada X yani yönü tanımlanamayan ya da atipik şekilde yerleşimliydi (Şekil 10B).



Şekil 10. A) Tümör lateralizasyonu B) Tümörlerin anatomik yönü

Tümör düzeyi açısından değerlendirildiğinde ise 36 (%18.3) hastada üst polde, 71 (%36.0) hastada orta polde, 62 (%31.5) hastada alt polde ve 28 (%14.2) hastada birden fazla poldeydi.



Şekil 11. BT verilerine göre tümörlerin böbrek düzeylerine göre dağılımı.

Hastalar nefrometri skoruna göre 8 ve 8'in altında ise düşük kompleksite (Grup-1), 9 ve 9'un üzerinde ise yüksek kompleksite (Grup-2) olarak gruplandırıldığında; Grup 1'de 107 (%54.31) hasta bulunurken, Grup-2'de 90 (%45.69) hasta mevcuttu. Verilerin incelenmesi Tablo 4'te sunulmuştur. Yaş ve cinsiyet dağılımı açısından değerlendirildiğinde gruplar arasında istatistiksel açıdan anlamlı farklılık saptanmamıştır. (sırasıyla $p=0.353$, $p=0.989$) Ancak tümör maksimum çapı grup 2'de istatistiksel olarak anlamlı derecede daha yüksek

bulunmuştur. ($p<0.001$) Ayrıca tümör yönü ve düzeyi de gruplar arasında farklılık içermektedir (sırasıyla $p=0.048$, $p<0.001$).

Tablo 4. Hastaların verilerinin gruplara göre karşılaştırılması

		Grup-1 n=(107)	Grup-2 n=(90)	p
Yaş (yıl)		61.80±11.37	60.28±11.56	0.353*
Cinsiyet n(%)	K	44(%41.1)	36(%40)	0.989**
	E	63(%58.9)	54(%60)	
Tümör Maksimum Çapı		3.64±1.79	7.50±2.88	<0.001*
Tümör Yönü n(%)	Anterior	38(%35.5)	35(%38.9)	0.048**
	Posterior	53(%49.5)	31(%34.4)	
	X	16(%15.0)	24(%26.7)	
Tümör Düzeyi n(%)	Üst Pol	25(%23.4)	11(%12.2)	<0.001**
	Orta Pol	40(%37.4)	31(%34.4)	
	Alt Pol	40(%37.4)	22(%24.4)	
	Birden fazla pol	2(%1.9)	26(%28.9)	

*: Student T testi, **: Pearson Ki Kare Analizi, X: Yönü tanımlanamayan ya da atipik şekilde yerleşimli

4.3. KORELASYON ANALİZİ SONUÇLARI


Sürekli değişkenler arasındaki doğrusal ilişki Pearson korelasyon analizi ile değerlendirilmiştir. Analiz sonucunda, tümör maksimum çapı ile nefrometri skoru arasında istatistiksel olarak anlamlı ve güçlü pozitif bir korelasyon saptanmıştır ($r = 0,718$; $p < 0,001$). Bu durum, tümör büyüklüğünün kompleksiteyi artırdığını desteklemektedir. Buna karşılık, tümör maksimum çapı ile yaş arasında zayıf ve istatistiksel olarak anlamlı olmayan negatif bir korelasyon gözlenmiştir ($r = -0,078$; $p = 0,275$). Benzer şekilde, yaş ile nefrometri skoru arasında da anlamlı bir ilişki bulunmamıştır ($r = -0,008$; $p = 0,915$). İlgili korelasyon katsayıları Tablo 5’te sunulmuştur.

Tablo 5. Tümör maksimum çapı, yaş ve nefrometri skoru arasındaki Pearson korelasyon katsayıları

		Tümör maksimum çapı	Yaş	Nefrometri skoru
Tümör maksimum çapı	Pearson Korelasyon p	1		
Yaş	Pearson Korelasyon p	-0,078 0,275	1	
Nefrometri skoru	Pearson Korelasyon p	,718** 0,000	-0,008 0,915	1

**, Korelasyon, 0.01 düzeyinde (çift yönlü) anlamlıdır.

4.4. ROC EĞRİSİ, AUC ANALİZİ VE MODEL PERFORMANSI



Şekil 12. Modelin ROC eğrisi ve AUC değeri.

Modelin sınıflandırma başarısını değerlendirmek amacıyla ROC (Receiver Operating Characteristic) eğrisi analiz edilmiştir. ROC eğrisi, modelin farklı eşik değerlerinde pozitif sınıfı ne ölçüde doğru tanıdığını gösteren, doğru pozitif oranı ile yanlış pozitif oranının ilişkisini grafiksel olarak sunar.

Bu çalışmada geliştirilen 3D CNN tabanlı model için oluşturulan ROC eğrisi Şekil 12’de gösterilmiştir. Eğri altında kalan alan (AUC) değeri 0.96 olarak elde edilmiştir. Bu değer, modelin yüksek doğrulukla sınıflar arasında ayırım yapabildiğini göstermektedir. AUC değeri 1’e yaklaştıkça modelin ayırt edici gücünün arttığı kabul edilir. Dolayısıyla bu çalışmada elde edilen AUC skoru, modelin tümör kompleksitesi sınıflandırma görevinde başarılı bir performans sergilediğini göstermektedir.


Yüksek AUC değeri, sınıflar arasında belirgin ayırım yapılabildiğini ve modelin öğrenme sürecinin etkin biçimde tamamlandığını destekler niteliktedir. Ayrıca, eğrinin 45°’lik referans çizgisinden diğer adıyla rastgele tahmin çizgisinden belirgin şekilde yukarıda konumlanması, modelin rastgele seçimden çok daha iyi performans gösterdiğinin bir diğer kanıtıdır.

4.5. SINIFLANDIRMA METRİKLERİ

4.5.1. Konfüzyon Matrisi Yorumlanması

	Düşük kompleksite	Yüksek kompleksite	
Düşük kompleksite	17 56.67%	0 0.00%	100.00% 0.00%
Yüksek kompleksite	3 10.00%	10 33.33%	76.92% 23.08%
	85.00% 15.00%	100.00% 0.00%	90.00% 10.00%

Şekil 13. Modelin detaylı yüzdesel ve renk kodlu karışıklık matrisi.



Şekil 14. Modelin sade karmaşıklık matrisi (heatmap gösterimi)

Modelin performansı değerlendirildiğinde, yukarıda gösterilmiş olan karmaşıklık matrisi elde edilmiştir. Bu matris, modelin iki sınıflı bir problemde yani “Düşük” ve “Yüksek” kompleksite grubunu ne ölçüde doğru sınıflandırma yaptığını göstermektedir. Burada düşük etiketi gerçek veya tahmin edilen düşük kompleksiteli tümör sınıfını, yüksek etiketi ise gerçek veya tahmin edilen yüksek kompleksiteli tümör sınıfını temsil etmektedir.

Şekil 13’te, her hücreye karşılık gelen sınıflandırma sonuçları hem sayı hem de yüzde oranlarıyla birlikte verilmiştir. Şekil 14’te ise aynı bilgiyi sadeleştirilmiş bir ısı haritası olarak sunmakta ve daha yalın bir görünüm sağlamaktadır.

Bu sonuçlara bakıldığında model, düşük kompleksite sınıfındaki tüm 17 vakayı doğru sınıflandırmış ve doğruluk oranı %100 olarak görülmektedir. Yüksek kompleksite sınıfında yer alan 13 örneğin 10’u doğru sınıflandırılmış, 3 tanesi ise düşük kompleksite olarak hatalı sınıflanmıştır. Modelin genel başarımı, özellikle “düşük kompleksite” sınıfında oldukça yüksek olup, “yüksek kompleksite” sınıfında

kısmen hatalı tahminler yapılmıştır. Bu durum, modelin düşük kompleksiteli tümörleri yüksek doğrulukla sınıflandırabildiğini; ancak yüksek kompleksite grubunda sınırlı ayırt edici başarı gösterdiğini göstermektedir.

4.5.2. Model Performans Metriklerinin Değerlendirilmesi

Karmaşıklık matrisini de göz önünde bulundurarak hesaplanabilecek bazı temel metriklerden yola çıkarak aşağıdaki tabloya ulaşabiliriz.

Tablo 6. Modelin düşük ve yüksek kompleksite sınıfları için sınıflandırma performans ölçütleri

	Kesinlik	Duyarlılık	f1-skoru	Örnek sayısı
Düşük	0.850	1.000000	0.918919	17.0
Yüksek	1.000	0.769231	0.869565	13.0
Genel doğruluk	0.900	0.900000	0.900000	0.9
Makro ortalama	0.925	0.884615	0.894242	30.0
Ağırlıklı ortalama	0.915	0.900000	0.897532	30.0

Bu tabloda, geliştirilen modelin R.E.N.A.L. nefrometri skoruna dayalı olarak tümör kompleksitesini düşük ve yüksek olarak sınıflandırırken gösterdiği performans ölçütleri sunulmaktadır. Doğruluk, modelin doğru olarak sınıflandırdığı pozitif örneklerin oranını; duyarlılık, gerçek pozitif vakaları tanıma başarısını; F1-skoru ise doğruluk ve duyarlılık arasındaki dengeyi ifade eder. Makro ortalama, her sınıfa eşit ağırlık vererek metriklerin ortalamasını hesaplar. Ağırlıklı ortalama ise sınıflardaki örnek sayısını dikkate alır. Makro ve ağırlıklı ortalamalar, sınıflar arası genel performansı değerlendirmek amacıyla kullanılmıştır. Bu değerler, modelin sınıflar üzerindeki başarı düzeyini karşılaştırmalı olarak ortaya koymaktadır. Bu tabloda düşük kompleksite grubunda model %100 duyarlılık ve %85 kesinlik elde etmiştir. Bu, modelin düşük kompleksiteli tümörleri tanımda oldukça başarılı olduğunu göstermektedir. Yüksek kompleksite grubunun duyarlılığı %76.9, kesinliği ise %100'dür. Yani model, yüksek kompleksiteli olarak tanıdığı örneklerde hata yapmamış; ancak bazı yüksek kompleksiteli hastaları düşük kompleksite olarak değerlendirmiştir. Genel doğruluk kısmına baktığımızda model tüm sınıflar dahil olmak üzere 30 örneğin 27'sini doğru sınıflandırarak %90 başarı sağlamıştır. Makro ortalama F1-skoru 0.89 ve ağırlıklı ortalama F1-skoru 0.897 olarak elde edilmiştir. Bu değerler, modelin iki sınıfta da dengeli bir performans sergilediğini göstermektedir. Bununla birlikte, özellikle yüksek kompleksite sınıfındaki daha düşük duyarlılık oranı, modelin bu sınıfa ait örneklerde sınırlı ayırt edicilik

gösterdiğini ortaya koymaktadır. Bu durum, ileride modelin bu sınıf için daha fazla örnekle eğitilmesi gerektiğine işaret etmektedir. Özellikle yüksek kompleksite grubundaki duyarlılık düşüklüğü, bu sınıfta örnek sayısının artırılmasının model performansını iyileştireceğini göstermektedir.

$$S_e = \frac{TP}{TP+FN}$$

$$S_p = \frac{TN}{TN+FP}$$

$$Pre = \frac{TP}{TP+FP}$$

$$F - score = \frac{2TP}{2TP+FP+FN}$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

		Actual value	
		Positive	Negative
Predicted	Positive	TP	FP
	Negative	FN	TN

Şekil 15. İstatistiksel analiz için kullanılan metrik değerleri için denklemler.

5. TARTIŞMA

Bu çalışmada, Afyonkarahisar Sağlık Bilimleri Üniversitesi Üroloji Kliniği'nde nefrektomi operasyonu geçirmiş ve histopatolojik olarak malign renal tümör tanısı almış 197 hastaya ait kontrastlı bilgisayarlı tomografi (BT) verileri kullanılarak, renal tümör kompleksitesinin R.E.N.A.L. nefrometri skorlarına göre sınıflandırılması amacıyla özgün bir derin öğrenme modeli geliştirilmiştir. Bu model segmentasyon temelli değil, doğrudan tümör kompleksitesini sınıflandırmaya yönelik olarak tasarlanmıştır. Sıfırdan inşa edilen üç boyutlu konvolüsyonel sinir ağı (3D CNN) mimarisi ile gerçekleştirilen bu modelleme çalışmasında, BT görüntü verileri $128 \times 128 \times 64$ boyutlarına yeniden örneklenerek işlenmiştir. Geliştirilen modelin genel sınıflandırma doğruluğu %90 olarak hesaplanmış, ROC analizine göre AUC (Eğri Altındaki Alan) skoru 0.96 bulunmuştur. Konfüzyon matrisi analizinde, düşük kompleksite grubundaki 17 vakanın tamamı doğru sınıflandırılmış ve bu sınıf için %100 duyarlılık elde edilmiştir. Yüksek kompleksite grubunda ise 13 vakanın 10'u doğru tahmin edilerek %76.9 duyarlılık sağlanmıştır. Ayrıca, korelasyon analizine göre tümör maksimum çapı ile nefrometri skoru arasında anlamlı ve güçlü pozitif ilişki ($r = 0.718$, $p < 0.001$) tespit edilmiştir.

Nefrometri skorları, renal kitlelerin cerrahi yönetiminde, parsiyel nefrektomi (PN) veya radikal nefrektomi (RN) kararı verilmesine rehberlik eden önemli objektif ölçütlerdir. Bu skor sistemleri, tümörün anatomik yerleşimi, boyutu ve çevre yapı ilişkisi gibi parametreleri değerlendirerek tümör kompleksitesini kantitatif biçimde ortaya koyar ve cerrahın preoperatif planlama sürecine doğrudan katkı sağlar.

Geliştirilen bu skorlamaların yalnızca cerrahi kararlarla sınırlı kalmayıp, aynı zamanda perioperatif komplikasyonlar, kan kaybı, operasyon süresi ve postoperatif renal fonksiyonlar gibi sonuçlarla da anlamlı şekilde ilişkili olabileceği düşünülmüş ve bu hipotezi test eden çok sayıda çalışma literatüre kazandırılmıştır.

Mevcut literatür incelendiğinde, farklı nefrometri skorlarının birbirleriyle karşılaştırıldığı, klinik geçerliliklerinin araştırıldığı ve prognostik değerlerinin test edildiği çeşitli validasyon çalışmalarının gerçekleştirildiği görülmektedir. Bu çalışmalar, skorların prediktif değerleri ve klinik karar destek sistemleri içerisindeki yerini daha iyi anlamak açısından önem taşımaktadır.

Yapay zeka alanındaki ilk çalışmalar, 1943 yılında insan beynindeki nöronların çalışma prensiplerini matematiksel olarak modellemeye yönelik girişimlerle başlamıştır. McCulloch ve W. Pitts tarafından geliştirilen bu yaklaşım, “eşik mantığı” olarak adlandırılmış ve yapay sinir ağlarının temelini oluşturmuştur (60). Yapay zeka araştırmaları temel olarak yapay sinir ağları ve karar ağaçları üzerine yoğunlaşmıştır. İnsan beyninden esinlenilerek çok katmanlı ağ yapısına sahip yapay sinir ağları geliştirmeye çalışmışlardır (61). Bu yaklaşımdan evrilen çok katmanlı yapay sinir ağları, özellikle derin öğrenme çağında hacimsel tıbbi görüntülerin analizinde yaygın biçimde kullanılmaya başlanmıştır. Bu çalışmada kullanılan üç boyutlu konvolüsyonel sinir ağı (3D CNN) mimarisi de bu tarihsel çizginin güncel bir uzantısı olarak değerlendirilmelidir. Geliştirilen model, hacimsel BT verileri üzerinde çok katmanlı filtreleme ve özellik çıkarımı yoluyla renal tümörlerin kompleksite düzeylerini öğrenmekte ve sınıflandırmaktadır. Bu bağlamda, ilk yapay nöron modellemesinden yola çıkılarak geliştirilen derin yapay sinir mimarileri, günümüzde yüksek çözünürlüklü tıbbi görüntülerin klinik karar destek süreçlerinde somut ve ölçülebilir katkılar sunmaktadır.

Bu tez çalışmasında, renal tümör kompleksitesinin değerlendirilmesinde yaygın olarak kullanılan R.E.N.A.L. nefrometri skoru temel alınarak, tümörlerin düşük veya yüksek kompleksiteli olarak sınıflandırılmasına yönelik derin öğrenme tabanlı bir model geliştirilmiş ve performansı analiz edilmiştir. R.E.N.A.L. nefrometri skoru, tümörün radyolojik özelliklerine dayalı olarak yapısal bir sınıflandırma sunmakta ve cerrahi planlamada önemli bir yol gösterici olarak kullanılmaktadır. Ancak bu skorun subjektif yorumlara açık olması ve manuel hesaplama gerekliliği, yapay zekâ tabanlı otomatik sistemlere olan ihtiyacı ortaya koymaktadır. Bu tartışma bölümünde, geliştirilen modelin bulguları mevcut literatürdeki benzer çalışmalar ışığında ele alınacak ve R.E.N.A.L. nefrometri skorunun sınıflandırma doğruluğu ve klinik öngörüye katkısı yapay zekâ ile entegrasyonu bağlamında değerlendirilecektir.

Literatürde yapay zekâ, böbrek kanseri tanısında erken müdahalenin sağkalım oranlarını artırdığı göz önüne alındığında, genel olarak böbrek tümörlerinin teşhisine, sınıflandırılmasına ve segmentasyonuna büyük avantajlar sunmaktadır (62–64).

Bizim çalışmamız, bu geniş alanın özel bir alt kümesi olan tümör kompleksite tahminiyle, karar alma süreçlerine özelleşmiş bir destek sağlamaktadır.

Çalışmamız, tek bir merkezden toplanan 197 hastaya ait kontrastlı portal faz BT görüntülerini kullanmıştır. Görüntüler, 128x128x64 boyutuna yeniden örneklendirilmiş ve tümör içeren bölgeler manuel veya yarı otomatik sınır kutuları (bounding box) ile belirlenerek ilgi alanına (ROI) odaklanılmıştır. Yoğunluk değerleri -1000 HU ile +400 HU arasında sınırlandırılıp 0-1 aralığına normalize edilmiştir. Bu ön işleme adımları, tıbbi görüntülemelerde derin öğrenme modelleri için yaygın ve gerekli uygulamalardır. Örneğin, bir çalışmada BT görüntülerinin -1000 HU'dan 2000 HU'ya kadar Hounsfield birimleriyle temsil edildiği ve böbrek alanlarını daha iyi analiz etmek için pencere genişliği ve seviyesinin ayarlandığı belirtilmiştir (64).

Yapay zeka ve radyomiks, tıbbi görüntülemenin geleneksel yorumlama yöntemlerinin sınırlamalarının üstesinden gelmek için böbrek lezyonlarının teşhisi, alt tip ayrımı, patolojik derecelendirilmesi ve cerrahi planlamasında umut vadeden yaklaşımlar sunmaktadır (65,66). Bu teknolojiler, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi görüntüleme araçlarından elde edilen niteliksel ve niceliksel verileri birleştirerek çalışır ve insan gözünden kaçabilecek ince özellikleri yakalama yeteneğine sahiptir. Tez çalışmamızda, geliştirilen özgün bir 3D CNN modeli sayesinde, BT verilerinden R.E.N.A.L. nefrometri skorlamaları kullanılarak otomatik olarak tümör kompleksitesi tahmin edilmiştir. Model, ROC eğrisi altında %96'lık AUC ve %90 genel doğruluk göstermiştir.

Bir çalışmada böbrek lezyonlarında malign ve benign tümör ayrımını yapabilen bir model üzerine yoğunlaşmıştır. Radyomiks, böbrek kanserini benign histolojiden ayırmada doğruluğu artırmayı hedeflemiştir. Yüksek verimli verilerden (BT ve MRI) çıkarılan histogramlar, dokular ve şekiller gibi niceliksel özelliklerin bolca elde edilebilmesi, son araştırmaları bu yöne doğru etkilemiştir (66). İlk çalışmalara bakılacak olursa Yu ve arkadaşları tarafından 119 hastada yapılan ilk çalışmalardan birinde, histogram tabanlı çarpıklık ve basıklık özelliklerini kullanarak böbrek kanserini onkositomdan ayırt etmede sırasıyla 0.91 ve 0.93 AUC (Eğri Altındaki Alan) bildirildi (67). Coy ve arkadaşları ise 200 hastada yaptıkları bir çalışmada malign ve benign lezyonları ayırt etmede 0.85 AUC elde etti (68). Bu

alışmalar, radyomiks ve makine ğreniminin (ML) bbrek lezyonlarının ayırımında potansiyelinin yksek olduėunu ortaya koymuřtur.

Geliřmiř performans aısından diėer alışmalara da bakarsak Erdim ve arkadaşları, kontrastsız BT grntlerinde 198, kontrastlı BT grntlerinde 244 zellik kullanarak, ML tabanlı random forest (RF) algoritmasıyla bbrek kanserini diėer benign bbrek kitlelerinden %90.5 doėruluk ve 0.915 AUC ile ayırt etmeyi bařardı (69) Koliner zellikler elimine edildiėinde bu deėerler %91.7 doėruluk ve 0.916 AUC'ye ykseldi. Zhou ve arkadaşları, InceptionV3 modeli adı verilen bir DL radyomiks modeli kullanarak 192 hastada %0.97 AUC (ROI verisi iin) ve %0.93 AUC bildirmiřtir (70). Sun ve arkadaşları ise 290 bbrek lezyonunda %0.93-0.94 AUC ile malign ve benign lezyonları ayırt eden bir radyomiks ML modeli sunmuřtur (71).

eřitli tarayıcılar zerinde performanslar aısından baktıėımızda Uhlig ve arkadaşları, 18 farklı BT tarayıcısından gelen verileri kullanarak RF algoritmasıyla malign ve benign T1 renal kitlelerini ayırt etmede 0.83 AUC elde etti, bu da radyologların deėerlendirmesinden (0.68 AUC) daha iyi bir sonutu (72). Bu, radyomiksin farklı tarayıcılar ve merkezler arasında bile iyi sonular verebileceėini gstermektedir. Ancak bizim alışmamızda kullanılan grnt verileri yalnızca iki farklı BT cihazından elde edilmiř olup, model farklı cihaz ve merkezlerde test edilmemiřtir. Bu durum, dıř geerlilik aısından nemli bir sınırlılık oluřturmaktadır.

Doėruluk ykseklėi aısından incelendiėinde Yu ve arkadaşları'nın 2024 yılında yaptıėı bir alışmada, bbrekteki intratmral ve peritmral radyomiks zellikler ile ekolojik eřitlilik zelliklerini birleřtirerek BT taramalarından elde edilen tm zellik kombinasyonları arasında en yksek AUC deėeri olan 0.929'u elde etmiřtir. Klinik faktrleri dahil ettikten sonra, kombine modelleri radyologların yorumlama performansını geride bırakmıřtır (0.946 AUC'ye karřı 0.823 AUC, $p < 0.001$). zellikle, kk bbrek lezyonları alt grubunda da modelin AUC'si 0.935'e ulařarak radyologlarınkinden (0.745 AUC) nemli lde yksek ıkmıřtır (73).

Bizim alışmamızda yalnızca histopatolojik olarak malign tanısı kesinleřmiř renal tmr vakalarını kapsamaktadır. Benign lezyonlar dıřlanmıřtır. Bu sayede

modelin eğitimi ve validasyonu sırasında malignite özellikleri üzerinden kompleksite analizi yapılabilmış, benign varyasyonların veri dengesini bozması engellenmiştir.

Benign böbrek lezyonlarından anjiyomyolipomlar üzerine de yapılmış çalışmalar dikkat çekmektedir. Feng ve arkadaşları, 42 BT'den elde edilen özellikten 16'sının AML'yi doğru bir şekilde teşhis etmede önemli bir intergrup farkı gösterdiğini değerlendiren ilk çalışmalardan birini yapmıştır. SVM özyinelemeli özellik eleme (recursive feature elimination) yöntemiyle en iyi özellikler seçilerek 0.939 AUC elde edildi (74). Cui ve arkadaşları, anjiyomyolipom (AML) ve böbrek tümörünü ayırt etmek için yaptığı bir diğer çalışmada ise SVM algoritması kullanarak 0.96 AUC bildirilmiştir (75). Bu konuda daha gelişmiş modeller hakkında yapılan çalışmalara baktığımızda Nie ve arkadaşları, ameliyat öncesi AML'yi RCC'den ayırmak için bir radyomiks nomogram geliştirmiş ve eğitim verisinde 0.879 AUC, doğrulama setinde ise 0.846 AUC elde etmiştir (76). Han ve arkadaşlarının çalışmaları da BT radyomikslerinin AML ve böbrek tümörünü ayırt etmedeki umut vadeden sonuçlarını desteklemektedir, sırasıyla 0.767 ve 0.783 AUC değerleri rapor edilmiştir (77). Bizim çalışmamızda anjiyomyolipom gibi benign tümör tipleri araştırmamız dışında bırakılmış olup, model yalnızca malign renal hücreli karsinom vakaları üzerinde eğitilmiştir. Bu durum, tümör kompleksitesine etki eden anatomik, boyutsal ve topografik parametrelerin analizinde daha bütüncül ve spesifik bir öğrenme süreci sağlanmasına olanak tanımıştır.

Yapay zeka aynı zamanda böbrek hücreli karsinomun patolojik derecelendirmesini de destekleyebilmektedir. Fuhrman derecelendirme sistemi günümüzde yaygın kullanılan bir sistemdir. 2012 yılında Uluslararası Patoloji Derneği (ISUP) de yeni bir derecelendirme sistemi tanıtmıştır. Geliştirilmiş olan yapay zeka modelleri, bu derecelendirmeleri BT ve MRI görüntüleri üzerinden tahmin etmede yüksek başarı göstermiştir. Örneğin, Zhao ve arkadaşları MRI kullanarak düşük ve yüksek dereceli RCC'leri ayırt etmede %0.88 doğruluk, %0.89 duyarlılık ve %0.88 özgüllük elde etmiştir (78). Yang ve arkadaşları tarafından geliştirilen entegre bir model ise %86.5 doğruluk ve 0.912 AUC ile daha iyi bir performans sergilemiştir (79). Bizim çalışmamızda doğrudan patolojik değerlendirme yapılmamış olmakla birlikte R.E.N.A.L. nefrometri skoruna göre düşük ve yüksek kompleksite sınıflandırması gerçekleştirilmiştir. Bu durumun

potansiyel olarak tümör agresifliğiyle ilişkili olabileceğinden prognostik açıdan bu şekilde katkı sağlayabileceği düşünülmektedir.

Yapay zeka tabanlı tanı modelleri böbrek tümörlerinde benign ve malign ayrımının yanı sıra, tümörün yavaş seyirli mi yoksa agresif seyirli mi olduğunu ayırt etmede de yüksek AUC değerleri göstermiştir. Bu modeller, agresif tümörlerin daha kötü rekürrensiz sağkalım (RFS), hastalığa özgü sağkalım (DSS) ve genel sağkalım (OS) oranlarına sahip olduğunu öngörmüştür. Çok değişkenli analizlerde, yapay zeka tahminli agresiflik alt tipleri, TNM evresi ve ISUP derecesine göre ayarlandıktan sonra bile hastanın sağkalımı için bağımsız bir olumsuz risk faktörü olarak kalmıştır (80). Her ne kadar bizim tezimizde doğrudan histopatolojik derecelendirme yapılmamış olsa da, çalışmada nefrometri skorunun tümör agresifliğiyle dolaylı ilişkisini temsil eden bir parametre olduğu düşünülmüştür. Nitekim korelasyon analizimizde tümör maksimum çapı ile nefrometri skoru arasında anlamlı ve güçlü pozitif bir ilişki tespit edilmiştir ($r = 0.718$; $p < 0.001$). Bu bulgu, büyük hacimli tümörlerin daha yüksek kompleksite özellikleri taşıdığını ve potansiyel olarak daha agresif davranış gösterebileceğini düşündürmektedir.

Yapay zeka 3D modeller geliştirilerek artırılmış gerçeklik ve sanal gerçeklik kullanılarak cerrahi planlamada da olumlu katkıları bulunmaktadır. Özellikle parsiyel nefrektomi gibi cerrahi prosedürlerde 3D modellerin, artırılmış gerçekliğin (AR) ve sanal gerçekliğin (VR) kullanılması, cerrahi kararları ve sonuçları önemli ölçüde etkileyebilmektedir. Sanal 3D modellerin kullanılması, ürolojik cerrahların renal anatomiye ilişkin mekansal farkındalığını ve ameliyat öncesi karar verme süreçlerini artırmaktadır. Çalışmalar, cerrahi planın %19'unda bir değişikliğin bildirildiğini ve sanal 3D modellerin cerrahın cerrahi kararlarına olan güvenini 5 hastadan 4'ünde artırdığını göstermiştir (81). Aynı zamanda bazı çalışmalar da göstermektedir ki 3D sanal modellerin kullanımı, ameliyat süresini, tahmini kan kaybını, klempleme süresini ve hastanede kalış süresini azaltabilmektedir (82). Ayrıca, Michiels ve arkadaşları tarafından yapılan bir çalışma, 3D böbrek rekonstrüksiyonlarının komplikasyon riskini azalttığını ve robot yardımlı parsiyel nefrektominin perioperatif klinik sonuçlarını iyileştirdiğini bulmuştur (83). Indocyanine green (ICG) rehberliğinde bilgisayar görüşü teknolojisi tabanlı otomatik artırılmış gerçeklik (AR) robot yardımlı parsiyel nefrektomi, 3D sanal modelin gerçek organa otomatik olarak

sabitlenmesini sağlayarak intraoperatif bilgiyi artırmakta ve cerrahın iş yükünü azaltmaktadır. Bizim çalışmamızda, BT verileri üç boyutlu voksel formatında ($128 \times 128 \times 64$) yeniden örneklenmiş ve model mimarisi bu hacimsel verileri girdi olarak işleyecek şekilde inşa edilmiştir. Geliştirilen 3D CNN modeli, dört ardışık konvolüsyon bloğuna ve ardından global average pooling ile dense katmanlara sahiptir. Eğitim sürecinde elde edilen konfüzyon matrisi sonuçlarına göre düşük kompleksite grubundaki 17 vakanın tamamı doğru sınıflandırılmış, yüksek kompleksite grubunda ise 13 vakanın 10'u doğru sınıflanmış ve modelin genel doğruluğu %90 olarak hesaplanmıştır.

Modelin, görüntü hacminden uzamsal özellikler çıkaran 3D Konvolüsyon katmanları, hacim boyutlarını azaltan 3D Maksimum Havuzlama katmanları ve öğrenmeyi hızlandırıp dengeleyen Batch Normalization katmanları gibi bileşenleri içermesi, 3D tıbbi görüntü analizinde literatürdeki diğer çalışmalarla karşılaştırıldığında standart ve etkili yöntemlerle uyumlu olduğu görülmektedir. Örneğin, Liu ve arkadaşlarının yaptığı bir çalışmada böbrek ve renal kitle segmentasyonu için sıfırdan geliştirilmiş, 3D Res-UNet tabanlı yeni bir uçtan uca teşhis çerçevesi önermiştir (64). Yin ve arkadaşlarının yaptığı bir çalışmada böbrekleri otomatik olarak segmentlere ayırmak için CNN'ler geliştirmiş, ardından bir 3D U-Net algoritması böbrek bölgelerinin ana hatlarını tahmin etmiştir (84).

R.E.N.A.L. ve PADUA gibi nefrometrik skorlama sistemleri, böbrek hücreli karsinom için parsiyel nefrektominin karmaşıklığını değerlendirmek için kullanılmaktadır. Bazı yeni geliştirilen görüntüleme yazılımları, BT anjiyografiden RCC'nin otomatik tespiti ve 3D görselleştirilmesini sağlamak üzere geliştirilmiştir. Bu yazılımlar, tümörlü böbreğin otomatik 3D görselleştirmesini sağlayarak nefrometrik skorların hesaplanmasına yardımcı olabilir, zaman kazandırabilir ve klinisyenler için tekrarlanabilirliği artırabilmektedir. Carlier ve arkadaşları tarafından yapılan bir çalışmada, otomatik yazılımın 3D görselleştirme ile tümörlü böbreği 20 saniyeden daha kısa sürede tespit edebildiği gösterilmiştir (85). Heller ve arkadaşları tarafından yapılan bir çalışma, bilgisayar tarafından oluşturulan R.E.N.A.L. nefrometri skorlarının, insan uzmanı skorlarıyla benzer prediktif sonuçlar verdiğini göstermiştir (86). Wood ve arkadaşları 2024 yılındaki çalışmasında tam otomatik nefrometri skorlarının (R.E.N.A.L, PADUA, C-İndeks, CSA) insan tarafından

hesaplanan skorlamalara kıyasla üstün prediktif fayda gösterdiğini ortaya koymuştur (87). Yapılan çalışmalarda otomatik skorlamanın, büyük veri setleri için tutarlılık ve kaliteyi artırma potansiyeline sahip olduğu düşünülmektedir. Bizim çalışmamızda R.E.N.A.L. nefrometri skoru, deneyimli bir radyolog tarafından BT görüntüleri üzerinden manuel olarak hesaplanmıştır. Bu skorlar daha sonra modelin hedef değişkeni olarak kullanılmış ve sınıflandırma modeli “düşük” (skor ≤ 8) ve “yüksek” (skor ≥ 9) kompleksite düzeylerini ayırt edecek biçimde eğitilmiştir. Modelin bu otomasyon kabiliyeti, gelecekte radyologların iş yükünü azaltabilecek ve subjektif farklılıkları ortadan kaldıracabilecek bir karar destek sistemi potansiyeli taşımaktadır. Özellikle düşük kompleksite grubunda %100 doğruluk sağlanması, klinik karar destek süreçleri açısından umut verici bulunmuştur.

Bu gelişmelerin ardında yatan temel teknikler derin öğrenme algoritmaları ve radyomiks yaklaşımlarıdır. Derin Evrimsel Sinir Ağları (ESA), hacimsel verilerin geometrik özelliklerini öğrenmek, değişken hacim boyutu ve GPU belleği kısıtlamaları gibi zorluklar içermektedir. Ancak, 3D CNN'ler (örneğin U-Net ve ResNet mimarileri) bu zorlukların üstesinden gelerek 3D bağlamı yakalayabilmekte ve 2D yaklaşımlardaki sınırlamaları giderebilmektedir (88). Z ekseninde spline interpolasyonu (SIZ) kullanan homojenleştirme teknikleri, hacimsel verilerin önemli düzeyde bilgi kaybetmeden işlenmesini sağlar ve 3D BT taramalarının daha iyi temsil edilmesini sağlayabilmektedir (89). Bizim çalışmamızda da İki boyutlu analizlerin sınırlı temsil gücünü aşmak amacıyla, çalışmamızda 3D BT görüntüleri üzerinden çalışan ve hacimsel bağlamı koruyarak öğrenme gerçekleştiren bir 3D CNN mimarisi kullanılmıştır. Böylece tümör kompleksitesi daha bütüncül şekilde değerlendirilebilmiştir.

Son yıllarda, böbrek ve böbrek tümörü segmentasyonu için otomatik yöntemler önemli ilerlemeler kaydetmiştir (90). Böbrek organının segmentasyonu için genellikle çok yüksek Dice katsayıları elde edilebilmektedir (91,92). Ancak, tümör segmentasyonu, özellikle de küçük, belirsiz sınırlara sahip veya heterojen tümörler için daha zordur (62,90,91). Bu zorlukların üstesinden gelebilmek için iki aşamalı yaklaşımlar, zayıf denetimli öğrenme, hibrid mimariler gibi çeşitli stratejiler geliştirilmiştir (62,64,92,93). Bununla birlikte, bizim çalışmamız doğrudan segmentasyon yerine, böbrek tümörlerinin R.E.N.A.L. nefrometri skorlarına göre

kompleksite düzeylerini sınıflandırmaya odaklanmıştır. Segmentasyon temelli modellerin yüksek Dice skorlarına ulaşmasına rağmen, küçük veya heterojen tümörlerde sınırlı performans göstermesi, sınıflandırma tabanlı alternatif yaklaşımların da önemini ortaya koymaktadır. Bu bağlamda, çalışmamızda sıfırdan geliştirilen 3D CNN modeli, segmentasyon ön işlemine gerek duymadan tümör kompleksitesini hacimsel BT verileri üzerinden doğrudan öğrenmiş ve %90 genel doğruluk ile 0.96 AUC gibi güçlü performans değerleri sergilemiştir. Bu yaklaşım, segmentasyonun zorluklarından kaçınarak hem işlem süresini kısaltmakta hem de klinik entegrasyon açısından daha pratik bir çözüm sunmaktadır.

Radyomiks, BT taramalarından doku, şekil ve yoğunluk gibi niceliksel özellikleri yüksek verimli bir şekilde çıkararak çalışmaktadır. Bu özellikler daha sonra makine öğrenimi modellerini (SVM, Random Forest vb.) eğitmek için kullanılmaktadır. Yapay zeka ile birleştirilmiş radyomiks, özellikle böbrek lezyonlarının karakterizasyonunda insan tanımlamasından kaçabilecek ince özellikleri yakalama yeteneğiyle geleneksel radyolojik tekniklerin teşhis, prognostik ve prediktif gücünü artırmıştır. YOLOv7 gibi modern YOLO versiyonları, BT dilimlerinden böbrek, tümör ve kist ROI (Region of Interest)'lerini yani ilgi bölgelerini çıkarmada yüksek performans göstermektedir. Özellikle çok küçük veya zorlu bölgelerin verimli bir şekilde tespitinde etkili olmaktadır (94). Literatürde sıkça karşılaşılan bunun gibi radyomiks temelli çalışmalar genellikle önceden tanımlanmış doku, histogram, şekil ve tekstür gibi özelliklerin elle ya da yarı otomatik yöntemlerle çıkarılmasını takiben SVM, Random Forest veya XGBoost gibi klasik makine öğrenme algoritmaları ile sınıflandırma yapılmasına dayanır. Bu yaklaşımlar, özellikle sınırlı sayıda örnek içeren veri setlerinde anlamlı sonuçlar üretse de, özellik çıkarım sürecinin manuel müdahaleye açık olması ve ROI belirleme işlemlerinin kullanıcıya bağımlılığı, modelin genellenebilirliğini sınırlayan temel etkenler arasında yer almaktadır. Bizim çalışmamızda kullanılan 3D konvolüsyonel sinir ağı (3D CNN) mimarisi, hacimsel BT verilerinin uzamsal ve yapısal özelliklerini öğrenebilecek şekilde bu sınırlamaları ortadan kaldırmak üzere sıfırdan geliştirilmiş ve literatürde yer alan ImageNet, U-Net ya da ResNet gibi önceden eğitilmiş mimarilerden bağımsız olarak yapılandırılmıştır (95,96). Bu, modelin doğrudan böbrek tümörü kompleksitesi sorununa yönelik optimize edildiğini göstermektedir.

Hacimsel veri boyutlarının yüksekliđi ve GPU bellek kısıtlamaları göz önüne alınarak, tüm veriler 128×128×64 voksel boyutlarına yeniden örneklenmiş ve bu süreçte ROI odaklı sınırlama uygulanarak gereksiz çevresel bilgiler dışlanmıştır. Ayrıca Hounsfield Unit (HU) değerleri –1000 ile +400 aralığında normalize edilerek, modelin stabil öğrenmesini destekleyecek tutarlı bir giriş uzayı sağlanmıştır. Eğitim sırasında kullanılan dropout (%50) ve batch normalization gibi teknikler, hem öğrenme hızını artırmış hem de aşırı öğrenme riskini azaltarak modelin genel doğruluk düzeyine (%90) katkı sağlamıştır. Ayrıca, modelin doğrudan R.E.N.A.L. nefrometri skoruna dayalı kompleksite sınıflandırması yapması, geleneksel radyomiks yaklaşımlardan farklı olarak, hedef değişkenin anatomik ve cerrahi açıdan anlamlı bir ölçüt olmasını sağlamıştır.

Yapay zekanın avantajları ve dezavantajlarını göz önünde bulundurduğumuzda önce avantajlarından bahsedecek olursak malign ve benign tümör ayrımı ve alt tip karakterizasyonunda radyologların performansını aşabilen yüksek doğruluk oranları sunabildiğini gösteren çalışmalar mevcuttur. Bizim tez çalışmamızda, geliştirilen model yalnızca yüksek doğruluk göstermekle kalmamış, aynı zamanda özellikle düşük kompleksite sınıfında mükemmel yakın performans sergilemiştir. Bu da cerrahi planlamada düşük riskli hastaların daha güvenle parsiyel nefrektomiye yönlendirilebilmesi için güçlü bir karar destek aracı olabileceğini göstermektedir.

3D modeller ve AR/VR (Augmented Reality/Virtual Reality) teknolojileri, cerrahların ameliyat öncesi daha iyi bir anatomik anlayış geliştirmesine, cerrahi kararlarını daha güvenli bir şekilde almasına ve potansiyel olarak ameliyat sonuçlarını iyileştirmesine olanak tanımaktadır. Çalışmamızda yüksek kompleksiteli tümörlerin önemli bir kısmının (yaklaşık %29'u) birden fazla renal polde yerleşim göstermesi, cerrahi planlama açısından kritik öneme sahiptir. Geliştirilen model bu tür topografik varyasyonları dikkate alarak yüksek kompleksiteyi doğru şekilde tahmin edebilmiştir.

Nefrometrik skorlama sistemlerinin otomatikleştirilmesi ve 3D görüntülemelerin hızla oluşturulması, klinisyenlerin zamanından tasarruf sağlar ve tekrarlanabilirliği artırmaktadır. Bizim çalışmamızda da manuel R.E.N.A.L. skorlamalarının zaman alıcı ve yorumcuya bağılı doğası göz önünde

bulundurulduğunda, modelin bu süreci otomatik hale getirmesi, klinik pratikte tutarlılığı ve hız kazanımını destekleyecektir.

Yapay zeka modellerinin dezavantajları ya da zorlukları incelendiğinde ise öncelikle modellerin eğitimi için büyük hacimli, yüksek kaliteli ve dengeli veri setlerine ihtiyaç duyulmaktadır. Özellikle at nalı böbrekler veya düşük kontrastlı BT taramaları gibi klasik olmayan senaryolarda yetersiz performans görülebilmektedir (97). Bizim çalışmamızda da veri seti tek merkezli olup homojen çekim protokollerinden oluşmaktadır. Bu durum iç geçerlik açısından avantaj sunsa da, modelin farklı merkezlerde test edilmemiş olması, dış geçerlilik açısından bir kısıt olarak karşımıza çıkmaktadır.

Farklı BT tarayıcıları, çekim protokolleri ve merkezler arasında modellerin genellenebilirliği bir zorluk teşkil etmektedir. Bizim çalışmamızda kullanılan görüntü verileri yalnızca iki cihazdan (Toshiba Aquilion Prime ve Siemens SOMATOM Force) elde edilmiştir. Bu nedenle farklı cihazlar, kontrast protokolleri ve hasta popülasyonlarında modelin performansı henüz test edilememiştir.

Radyomiks ve yapay zekanın gerçek klinik faydasını değerlendirmek için histopatolojik sonuçlara ek olarak insan görüntüleme değerlendirmesiyle karşılaştırma önemli olmaktadır. Bizim çalışmamızda modelin sınıflandırma çıktıları, radyolog tarafından yapılan R.E.N.A.L. skorları ile karşılaştırılmış ve yüksek düzeyde uyum gözlemlenmiştir. Ancak daha geniş karşılaştırmalı çalışmalarla klinik güvenilirlik düzeyi artırılmalıdır.

Yapay zeka sistemlerinin tahminlerine güven oluşturmak ve klinik kullanımda bu sistemlerin şeffaflığını sağlamak kritik öneme sahiptir. Bizim çalışmamızda tüm hasta verileri anonimleştirilmiş, çalışma için ilgili etik kurul onayı alınmıştır. Yapay zeka sistemlerinin klinik uygulamalarda yaygınlaşabilmesi için etik şeffaflık ve kullanıcı güveni temel zorunluluklardır.

Son olarak, bu çalışma, renal tümör kompleksitesinin radyolojik verilerle görüntülerin otomatik sınıflandırılmasına yönelik yapay zeka tabanlı sınırlı sayıda yapılmış klinik odaklı modellerden biri olarak değerlendirilebilir. Geliştirilen özgün 3D CNN mimarisi, yalnızca yüksek sınıflandırma performansı sunmakla kalmamış; aynı zamanda manuel nefrometri skorlamalarının doğasında bulunan subjektiflik,

zaman kaybı ve yorumlayıcı bağımlılığını ortadan kaldırabilecek potansiyel bir klinik çözüm sunmuştur. Modelin düşük kompleksiteli tümörleri %100 duyarlılıkla tanımlayabilmesi, parsiyel nefrektomiye yönlendirilecek hastaların seçilmesinde doğrudan kullanılacak düzeyde güvenilirlik ve yol göstericilik sunarken; yüksek kompleksiteli lezyonlarda elde edilen başarı da total nefrektomi gibi daha invazif yaklaşımlar için cerrahların risk değerlendirme süreçlerine katkı sağlayacak niteliktedir. Bu yönüyle model, yalnızca bir akademik prototip olmanın ötesinde, cerrahi karar mekanizmalarına entegre edilebilir, objektif, hızlı ve tekrarlanabilir bir karar destek aracı olarak öne çıkmaktadır. Literatürde radyomiks ve derin öğrenme modellerinin böbrek lezyonlarını ayırt etme konusundaki başarısı giderek artmakla birlikte, bu çalışmada doğrudan kompleksiteye odaklanan, segmentasyon ihtiyacı duymadan çalışan ve hacimsel BT verisi üzerinden eğitim almış özgün bir modelin sunulması, literatüre metodolojik yenilik ve klinik pratikte uygulanabilirlik açısından önemli bir katkı sunmaktadır.

Bununla birlikte, modelin yüksek kompleksite grubundaki duyarlılığı %76.9 olarak saptanmıştır ki bu değer düşük kompleksite grubundaki %100 duyarlılıkla karşılaştırıldığında belirgin şekilde düşük olduğu düşünülebilir. Bu farkın olası nedenleri arasında, yüksek kompleksite grubuna ait örnek sayısının daha az olması, bu grubun yapısal ve anatomik açıdan daha heterojen bir dağılım göstermesi ve sınıf dengesizliği sayılabilir. Ayrıca, karmaşık anatomik varyasyonların model tarafından yeterince genellenememesi de bu sonucu etkileyebilir.

Öte yandan, bu çalışmanın sınırlı veri setine sahip olması nedeniyle ilerideki çalışmalarda modelin çok merkezli veri setleriyle test edilmesi, farklı görüntüleme cihazlarıyla uyumunun araştırılması ve cerrahların intraoperatif karar süreçlerine entegrasyonu gibi alanlar, bu alandaki gelişimin sürekliliğini sağlayacağını düşünmekteyiz. Yapay zeka, geleneksel görüntü yorumlama paradigmasını dönüştürerek klinik kararlara hız, hassasiyet ve tutarlılık kazandırmaktadır; bu çalışma ise bu dönüşümün üroonkoloji pratiğinde nasıl somutlaştırılabileceğine dair etkili ve umut verici bir örnek olarak değerlendirilmelidir.

6. SONUÇLAR

Bu tez çalışmasında, böbrek tümörlerinin cerrahi yönetiminde önemli bir belirleyici olan tümör kompleksitesinin, R.E.N.A.L. nefrometri skorlaması temel alınarak otomatik olarak sınıflandırılmasını sağlayan derin öğrenme tabanlı bir model geliştirilmiş ve başarıyla uygulanmıştır. Kontrastlı bilgisayarlı tomografi (BT) görüntülerinden elde edilen hacimsel verilerle eğitilen sıfırdan tasarlanmış üç boyutlu konvolüsyonel sinir ağı (3D-CNN), renal kitleleri düşük ve yüksek kompleksiteli olarak ayırmada yüksek doğruluk (AUC: 0.96, genel başarı: %90) sergilemiş; bu yönüyle, cerrahi yaklaşım seçiminde (parsiyel nefrektomi vs. total nefrektomi) güçlü bir klinik karar destek sistemi niteliği kazanmıştır.

Manuel yapılan nefrometri skorlamaları, radyologun deneyimine ve yorumuna bağlı olarak değişkenlik göstermekte, zaman alıcı süreçler içermekte ve sınırlı standardizasyon sağlamaktadır. Bu çalışma ile geliştirilen otomatik sınıflandırma modeli, tümör kompleksitesini objektif biçimde değerlendirme imkânı sunarak bu sınırlılıkları önemli ölçüde aşmıştır. Model, düşük kompleksiteli vakalarda %100 duyarlılık ile tümörleri doğru sınıflandırabilmiş; yüksek kompleksiteli vakalarda ise %76.9 duyarlılıkla belirleyici olmuştur. Özellikle düşük kompleksite grubunda gösterilen bu yüksek başarı, nefron koruyucu cerrahi (NKC) adaylarının güvenle belirlenmesine olanak tanımaktadır. Yüksek kompleksite grubunda ise modelin doğru sınıfladığı hastalar, cerrahi açıdan daha riskli vakalar olup, radikal yani total nefrektomiye yönlendirilmesi gereken grubu temsil etmektedir.

Bu bağlamda, modelin sağladığı sınıflandırma çıktısı, doğrudan cerrahi planlama kararına entegre edilebilecek potansiyele sahiptir. Klinik pratikte, düşük kompleksite grubuna giren hastalarda böbrek fonksiyonunun maksimum korunmasını sağlayan parsiyel nefrektomi güvenle tercih edilebilirken; yüksek kompleksite grubunda ise tümörün lokal invazyon potansiyeli ve cerrahi zorluk göz önüne alınarak total nefrektomi daha uygun bir seçenek haline gelebilmektedir. Dolayısıyla, bu yapay zeka destekli sistem, yalnızca sınıflandırma başarısıyla değil, aynı zamanda cerrahın tedavi stratejisini biçimlendiren doğrudan etkisiyle de öne çıkmaktadır.

Ayrıca korelasyon analizleri, tümör maksimum çapı ile nefrometri skoru arasında güçlü pozitif bir ilişki olduğunu ($r = 0.718$, $p < 0.001$) ortaya koyarak modelin tıbbi gerçekliklerle tutarlılığını da kanıtlamıştır. Bu bulgu, tümör boyutunun kompleksite üzerindeki belirleyici etkisini vurgularken, modelin biyolojik temele dayalı olarak güvenilir çıktılar ürettiğini göstermektedir.

Yine de bu çalışma bazı metodolojik ve teknik sınırlamalara sahiptir. Veri seti tek merkezli olup, iki farklı BT cihazından elde edilen görüntülerle sınırlıdır. Farklı cihaz türlerinde, merkezlerde ve popülasyonlarda modelin performansının nasıl değişeceği henüz bilinmemektedir. Ayrıca çalışmaya sadece malignite tanısı almış, nefrektomi geçirmiş ve yeterli görüntü kalitesine sahip vakalar dahil edilmiştir. Bu durum, modelin benign lezyonlara ya da önceden tedavi almış hastalara uygulanabilirliğini sınırlandırmaktadır. Yüksek kompleksite grubunda örnek sayısının görece düşük olması ise bu gruptaki duyarlılığın sınırlı kalmasına neden olmuştur.

Gelecekteki çalışmalar, modelin genellenebilirliğini artırmak amacıyla farklı merkezlerden elde edilmiş, daha büyük ve dengeli veri setleriyle desteklenmeli; ayrıca transfer öğrenme veya çok modellenli stratejilerle daha rafine mimariler geliştirilmelidir. Gerçek zamanlı klinik ortamlarda uygulanabilirliği test edilerek, BT cihazlarına entegre olabilecek kullanıcı dostu yazılımlar haline getirilmesi hedeflenmelidir.

Sonuç olarak, bu tez çalışmasıyla geliştirilen 3D-CNN temelli yapay zekâ modeli, renal tümörlerin kompleksite düzeyini doğru biçimde sınıflandırarak, parsiyel ya da total nefrektomi kararı aşamasında klinisyenlere etkin destek sunabilecek düzeyde başarılı sonuçlar üretmiştir. Cerrahi planlamayı doğrudan etkileyen bu tür yapay zeka destekli sistemler, üroonkoloji pratiğinde daha güvenli, standart ve bireyselleştirilmiş tedavi kararlarının alınmasını kolaylaştırmakta ve hasta yararını önceleyen modern tıp anlayışına güçlü katkılar sunmaktadır. Bu bağlamda, çalışmamız tıpta yapay zeka uygulamalarının klinik karar süreçlerinde doğrudan etkin hale geldiği yeni bir dönemin örneklerinden olarak değerlendirilebilir.

7. KAYNAKÇA

1. Ertekin E, Amasyalı AS, Erol B, Acikgozoglul S, Kucukdurmaz F, Nayman A, et al. Role of Contrast Enhancement and Corrected Attenuation Values of Renal Tumors in Predicting Renal Cell Carcinoma (RCC) Subtypes: Protocol for a Triphasic Multi-Slice Computed Tomography (CT) Procedure. *Pol J Radiol*. 2017 July 16;82:384–91.
2. Ljungberg B, Hanbury DC, Kuczyk MA, Merseburger AS, Mulders PF, Patard JJ, et al. Renal cell carcinoma guideline. *Eur Urol*. 2007;51(6):1502–10.
3. Ljungberg B, Albiges L, Abu-Ghanem Y, Bedke J, Capitanio U, Dabestani S, et al. European Association of Urology guidelines on renal cell carcinoma: the 2022 update. *Eur Urol*. 2022;82(4):399–410.
4. Motzer RJ, Nanus DM, Russo P, Berg WJ. Renal cell carcinoma. *Curr Probl Cancer*. 1997 July 1;21(4):185–232.
5. Yuan JM, Castelaol JE, Gago-Dominguez M, Yu MC, Ross RK. Tobacco use in relation to renal cell carcinoma. *Cancer Epidemiol Biomark Prev Publ Am Assoc Cancer Res Cosponsored Am Soc Prev Oncol*. 1998;7(5):429–33.
6. Yuan JM, Castelaol JE, Gago-Dominguez M, Ross RK, Yu MC. Hypertension, obesity and their medications in relation to renal cell carcinoma. *Br J Cancer*. 1998;77(9):1508–13.
7. Ljungberg B, Bensalah K, Canfield S, Dabestani S, Hofmann F, Hora M, et al. EAU guidelines on renal cell carcinoma: 2014 update. *Eur Urol*. 2015 May;67(5):913–24.
8. Leibovich BC, Lohse CM, Crispen PL, Boorjian SA, Thompson RH, Blute ML, et al. Histological subtype is an independent predictor of outcome for patients with renal cell carcinoma. *J Urol*. 2010 Apr;183(4):1309–15.
9. Low G, Huang G, Fu W, Moloo Z, Girgis S. Review of renal cell carcinoma and its common subtypes in radiology. *World J Radiol*. 2016 May 28;8(5):484–500.

10. Shah RB, Bakshi N, Hafez KS, Wood Jr DP, Kunju LP. Image-guided biopsy in the evaluation of renal mass lesions in contemporary urological practice: indications, adequacy, clinical impact, and limitations of the pathological diagnosis. *Hum Pathol*. 2005;36(12):1309–15.
11. Ficarra V, Galfano A, Mancini M, Martignoni G, Artibani W. TNM staging system for renal-cell carcinoma: current status and future perspectives. *Lancet Oncol*. 2007 June;8(6):554–8.
12. Ward RD, Tanaka H, Campbell SC, Remer EM. 2017 AUA Renal Mass and Localized Renal Cancer Guidelines: Imaging Implications. *Radiogr Rev Publ Radiol Soc N Am Inc*. 2018;38(7):2021–33.
13. Barata PC, Rini BI. Treatment of renal cell carcinoma: Current status and future directions. *CA Cancer J Clin*. 2017 Nov;67(6):507–24.
14. Malthouse T, Kasivisvanathan V, Raison N, Lam W, Challacombe B. The future of partial nephrectomy. *Int J Surg Lond Engl*. 2016 Dec;36(Pt C):560–7.
15. Simmons MN, Lieser GC, Fergany AF, Kaouk J, Campbell SC. Association between warm ischemia time and renal parenchymal atrophy after partial nephrectomy. *J Urol*. 2013 May;189(5):1638–42.
16. Godoy G, Ramanathan V, Kanofsky JA, O'Malley RL, Tareen BU, Taneja SS, et al. Effect of warm ischemia time during laparoscopic partial nephrectomy on early postoperative glomerular filtration rate. *J Urol*. 2009 June;181(6):2438–43; discussion 2443–2445.
17. Lane BR, Babineau DC, Poggio ED, Weight CJ, Larson BT, Gill IS, et al. Factors predicting renal functional outcome after partial nephrectomy. *J Urol*. 2008 Dec;180(6):2363–8; discussion 2368–2369.
18. Sobin, Leslie H., Gospodarowicz, Mary K. *TNM Classification of Malignant Tumours*. 7th ed. Hoboken: John Wiley & Sons; 2011.
19. Amin MB, Greene FL, Edge SB, Compton CC, Gershenwald JE, Brookland RK, et al. The Eighth Edition AJCC Cancer Staging Manual: Continuing to build a bridge from a population-based to a more “personalized” approach to cancer staging. *CA Cancer J Clin*. 2017 Mar;67(2):93–9.

20. Capitanio U, Bedke J, Albiges L, Volpe A, Giles RH, Hora M, et al. A Renewal of the TNM Staging System for Patients with Renal Cancer To Comply with Current Decision-making: Proposal from the European Association of Urology Guidelines Panel. *Eur Urol*. 2023 Jan;83(1):3–5.
21. Kutikov A, Uzzo RG. The R.E.N.A.L. nephrometry score: a comprehensive standardized system for quantitating renal tumor size, location and depth. *J Urol*. 2009 Sept;182(3):844–53.
22. Buethe DD, Moussly S, Lin HY, Yue B, Rodriguez AR, Spiess PE, et al. Is the R.E.N.A.L. nephrometry scoring system predictive of the functional efficacy of nephron sparing surgery in the solitary kidney? *J Urol*. 2012 Sept;188(3):729–35.
23. Zhou HJ, Yan Y, Zhang JZ, Liang LR, Guo SB. Role of R.E.N.A.L. Nephrometry Score in Laparoscopic Partial Nephrectomy. *Chin Med J (Engl)*. 2017 Sept 20;130(18):2170–5.
24. Miyake H, Furukawa J, Hinata N, Muramaki M, Tanaka K, Fujisawa M. Significant impact of R.E.N.A.L. nephrometry score on changes in postoperative renal function early after robot-assisted partial nephrectomy. *Int J Clin Oncol*. 2015 June;20(3):586–92.
25. Yoshida K, Kinoshita H, Yoshida T, Takayasu K, Mishima T, Yanishi M, et al. Comparison of diameter-axial-polar nephrometry score and RENAL nephrometry score for surgical outcomes following laparoscopic partial nephrectomy. *Int J Urol Off J Jpn Urol Assoc*. 2016 Feb;23(2):148–52.
26. Vogel C, Ziegelmüller B, Ljungberg B, Bensalah K, Bex A, Canfield S, et al. Imaging in Suspected Renal-Cell Carcinoma: Systematic Review. *Clin Genitourin Cancer*. 2019 Apr;17(2):e345–55.
27. Gong IH, Hwang J, Choi DK, Lee SR, Hong YK, Hong JY, et al. Relationship among total kidney volume, renal function and age. *J Urol*. 2012 Jan;187(1):344–9.
28. Shi X, Feng D, Li D, Zhang F, Wei W. The Role of Lymph Node Dissection for Non-Metastatic Renal Cell Carcinoma: An Updated Systematic Review and Meta-Analysis. *Front Oncol*. 2021;11:790381.

29. Ferda J, Hora M, Hes O, Ferdová E, Kreuzberg B. Assessment of the kidney tumor vascular supply by two-phase MDCT-angiography. *Eur J Radiol.* 2007 May;62(2):295–301.
30. Shao P, Tang L, Li P, Xu Y, Qin C, Cao Q, et al. Precise segmental renal artery clamping under the guidance of dual-source computed tomography angiography during laparoscopic partial nephrectomy. *Eur Urol.* 2012 Dec;62(6):1001–8.
31. Kane CJ, Mallin K, Ritchey J, Cooperberg MR, Carroll PR. Renal cell cancer stage migration: analysis of the National Cancer Data Base. *Cancer.* 2008 July 1;113(1):78–83.
32. Robson CJ, Churchill BM, Anderson W. The results of radical nephrectomy for renal cell carcinoma. *J Urol.* 1969 Mar;101(3):297–301.
33. Terrone C, Guercio S, De Luca S, Poggio M, Castelli E, Scoffone C, et al. The number of lymph nodes examined and staging accuracy in renal cell carcinoma. *BJU Int.* 2003 Jan;91(1):37–40.
34. Studer UE, Scherz S, Scheidegger J, Kraft R, Sonntag R, Ackermann D, et al. Enlargement of regional lymph nodes in renal cell carcinoma is often not due to metastases. *J Urol.* 1990 Aug;144(2 Pt 1):243–5.
35. Capitanio U, Becker F, Blute ML, Mulders P, Patard JJ, Russo P, et al. Lymph node dissection in renal cell carcinoma. *Eur Urol.* 2011 Dec;60(6):1212–20.
36. Dimashkieh HH, Lohse CM, Blute ML, Kwon ED, Leibovich BC, Cheville JC. Extranodal extension in regional lymph nodes is associated with outcome in patients with renal cell carcinoma. *J Urol.* 2006 Nov;176(5):1978–82; discussion 1982–1983.
37. Terrone C, Cracco C, Porpiglia F, Bollito E, Scoffone C, Poggio M, et al. Reassessing the current TNM lymph node staging for renal cell carcinoma. *Eur Urol.* 2006 Feb;49(2):324–31.
38. Buffi N, Lista G, Larcher A, Lughezzani G, Ficarra V, Cestari A, et al. Margin, ischemia, and complications (MIC) score in partial nephrectomy: a

- new system for evaluating achievement of optimal outcomes in nephron-sparing surgery. *Eur Urol.* 2012 Oct;62(4):617–8.
39. Zargar H, Porpiglia F, Porter J, Quarto G, Perdoni S, Bertolo R, et al. Achievement of trifecta in minimally invasive partial nephrectomy correlates with functional preservation of operated kidney: a multi-institutional assessment using MAG3 renal scan. *World J Urol.* 2016 July;34(7):925–31.
 40. Minervini A, Siena G, Antonelli A, Bianchi G, Bocciardi AM, Cosciani Cunico S, et al. Open versus laparoscopic partial nephrectomy for clinical T1a renal masses: a matched-pair comparison of 280 patients with TRIFECTA outcomes (RECORD Project). *World J Urol.* 2014 Feb;32(1):257–63.
 41. Khalifeh A, Autorino R, Hillyer SP, Laydner H, Eyraud R, Panumatrassamee K, et al. Comparative outcomes and assessment of trifecta in 500 robotic and laparoscopic partial nephrectomy cases: a single surgeon experience. *J Urol.* 2013 Apr;189(4):1236–42.
 42. Yaman, M. Campbell's Urology. In: Campbell-Walsh Üroloji. 10th ed. İstanbul: Nobel Tıp Kitabevleri; 2014. p. 1413–74.
 43. Herr HW. A history of partial nephrectomy for renal tumors. *J Urol.* 2005 Mar;173(3):705–8.
 44. Touijer K, Jacqmin D, Kavoussi LR, Montorsi F, Patard JJ, Rogers CG, et al. The expanding role of partial nephrectomy: a critical analysis of indications, results, and complications. *Eur Urol.* 2010 Feb;57(2):214–22.
 45. Lane BR, Babineau DC, Poggio ED, Weight CJ, Larson BT, Gill IS, et al. Factors predicting renal functional outcome after partial nephrectomy. *J Urol.* 2008 Dec;180(6):2363–8; discussion 2368-2369.
 46. Lau WK, Blute ML, Weaver AL, Torres VE, Zincke H. Matched comparison of radical nephrectomy vs nephron-sparing surgery in patients with unilateral renal cell carcinoma and a normal contralateral kidney. *Mayo Clin Proc.* 2000 Dec;75(12):1236–42.
 47. Novick AC, Derweesh I. Open partial nephrectomy for renal tumours: current status. *BJU Int.* 2005 Mar;95 Suppl 2:35–40.

48. Leow JJ, Heah NH, Chang SL, Chong YL, Png KS. Outcomes of Robotic versus Laparoscopic Partial Nephrectomy: an Updated Meta-Analysis of 4,919 Patients. *J Urol*. 2016 Nov;196(5):1371–7.
49. Dabestani S, Beisland C, Stewart GD, Bensalah K, Gudmundsson E, Lam TB, et al. Increased use of cross-sectional imaging for follow-up does not improve post-recurrence survival of surgically treated initially localized R.C.C.: results from a European multicenter database (R.E.C.U.R.). *Scand J Urol*. 2019 Feb;53(1):14–20.
50. Capitanio U, Larcher A, Cianflone F, Trevisani F, Nini A, Mottrie A, et al. Hypertension and Cardiovascular Morbidity Following Surgery for Kidney Cancer. *Eur Urol Oncol*. 2020 Apr;3(2):209–15.
51. Sandhu SS, Symes A, A'Hern R, Sohaib SAA, Eisen T, Gore M, et al. Surgical excision of isolated renal-bed recurrence after radical nephrectomy for renal cell carcinoma. *BJU Int*. 2005 Mar;95(4):522–5.
52. Bani-Hani AH, Leibovich BC, Lohse CM, Cheville JC, Zincke H, Blute ML. Associations with contralateral recurrence following nephrectomy for renal cell carcinoma using a cohort of 2,352 patients. *J Urol*. 2005 Feb;173(2):391–4.
53. European Association of Urology. EAU Guidelines. Presented at the EAU Annual Congress Milan 2023. Arnhem, The Netherlands: European Association of Urology; 2023.
54. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436–44.
55. Do S, Song KD, Chung JW. Basics of Deep Learning: A Radiologist's Guide to Understanding Published Radiology Articles on Deep Learning. *Korean J Radiol*. 2020 Jan;21(1):33–41.
56. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. *Insights Imaging*. 2018 Aug;9(4):611–29.

57. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide. *Radiology*. 2019 Mar;290(3):590–606.
58. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proc IEEE*. 1998;86(11):2278–324.
59. Tan Z, Yang X, Huang K. Semantic-aware data augmentation for text-to-image synthesis. In: *Proceedings of the AAAI Conference on Artificial Intelligence* [Internet]. 2024 [cited 2025 June 24]. p. 5098–107. Available from: <https://ojs.aaai.org/index.php/AAAI/article/view/28315>
60. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. 1943. *Bull Math Biol*. 1990;52(1–2):99–115; discussion 73-97.
61. Cengil E, Çınar A. A new approach for image classification: convolutional neural network. *Eur J Tech EJT*. 2016;6(2):96–103.
62. Hu W, Yang S, Guo W, Xiao N, Yang X, Ren X. STC-UNet: renal tumor segmentation based on enhanced feature extraction at different network levels. *BMC Med Imaging*. 2024 July 19;24(1):179.
63. da Cruz LB, Araújo JDL, Ferreira JL, Diniz JOB, Silva AC, de Almeida JDS, et al. Kidney segmentation from computed tomography images using deep neural network. *Comput Biol Med*. 2020 Aug;123:103906.
64. Liu J, Yildirim O, Akin O, Tian Y. AI-Driven Robust Kidney and Renal Mass Segmentation and Classification on 3D CT Images. *Bioeng Basel Switz*. 2023 Jan 13;10(1):116.
65. Mühlbauer J, Egen L, Kowalewski KF, Grilli M, Walach MT, Westhoff N, et al. Radiomics in Renal Cell Carcinoma-A Systematic Review and Meta-Analysis. *Cancers*. 2021 Mar 17;13(6):1348.
66. Ferro M, Crocetto F, Barone B, Del Giudice F, Maggi M, Lucarelli G, et al. Artificial intelligence and radiomics in evaluation of kidney lesions: a comprehensive literature review. *Ther Adv Urol*. 2023;15:17562872231164803.

67. Yu H, Scalera J, Khalid M, Touret AS, Bloch N, Li B, et al. Texture analysis as a radiomic marker for differentiating renal tumors. *Abdom Radiol N Y*. 2017 Oct;42(10):2470–8.
68. Coy H, Young JR, Douek ML, Brown MS, Sayre J, Raman SS. Quantitative computer-aided diagnostic algorithm for automated detection of peak lesion attenuation in differentiating clear cell from papillary and chromophobe renal cell carcinoma, oncocytoma, and fat-poor angiomyolipoma on multiphasic multidetector computed tomography. *Abdom Radiol N Y*. 2017 July;42(7):1919–28.
69. Erdim C, Yardimci AH, Bektas CT, Kocak B, Koca SB, Demir H, et al. Prediction of Benign and Malignant Solid Renal Masses: Machine Learning-Based CT Texture Analysis. *Acad Radiol*. 2020 Oct;27(10):1422–9.
70. Zhou L, Zhang Z, Chen YC, Zhao ZY, Yin XD, Jiang HB. A Deep Learning-Based Radiomics Model for Differentiating Benign and Malignant Renal Tumors. *Transl Oncol*. 2019 Feb;12(2):292–300.
71. Sun XY, Feng QX, Xu X, Zhang J, Zhu FP, Yang YH, et al. Radiologic-Radiomic Machine Learning Models for Differentiation of Benign and Malignant Solid Renal Masses: Comparison With Expert-Level Radiologists. *AJR Am J Roentgenol*. 2020 Jan;214(1):W44–54.
72. Uhlig J, Biggemann L, Nietert MM, Beißbarth T, Lotz J, Kim HS, et al. Discriminating malignant and benign clinical T1 renal masses on computed tomography: A pragmatic radiomics and machine learning approach. *Medicine (Baltimore)*. 2020 Apr;99(16):e19725.
73. Yu S, Yang Y, Wang Z, Zheng H, Cui J, Zhan Y, et al. CT-based conventional radiomics and quantification of intratumoral heterogeneity for predicting benign and malignant renal lesions. *Cancer Imaging Off Publ Int Cancer Imaging Soc*. 2024 Oct 2;24(1):130.
74. Feng Z, Rong P, Cao P, Zhou Q, Zhu W, Yan Z, et al. Machine learning-based quantitative texture analysis of CT images of small renal masses: Differentiation of angiomyolipoma without visible fat from renal cell carcinoma. *Eur Radiol*. 2018 Apr;28(4):1625–33.

75. Cui EM, Lin F, Li Q, Li RG, Chen XM, Liu ZS, et al. Differentiation of renal angiomyolipoma without visible fat from renal cell carcinoma by machine learning based on whole-tumor computed tomography texture features. *Acta Radiol Stockh Swed* 1987. 2019 Nov;60(11):1543–52.
76. Nie P, Yang G, Wang Z, Yan L, Miao W, Hao D, et al. A CT-based radiomics nomogram for differentiation of renal angiomyolipoma without visible fat from homogeneous clear cell renal cell carcinoma. *Eur Radiol*. 2020 Feb;30(2):1274–84.
77. Han Z, Zhu Y, Xu J, Wen D, Xia Y, Zheng M, et al. Predictive Value of CT-Based Radiomics in Distinguishing Renal Angiomyolipomas with Minimal Fat from Other Renal Tumors. *Dis Markers*. 2022;2022:9108129.
78. Zhao Y, Chang M, Wang R, Xi IL, Chang K, Huang RY, et al. Deep Learning Based on MRI for Differentiation of Low- and High-Grade in Low-Stage Renal Cell Carcinoma. *J Magn Reson Imaging JMRI*. 2020 Nov;52(5):1542–9.
79. Yang M, He X, Xu L, Liu M, Deng J, Cheng X, et al. CT-based transformer model for non-invasively predicting the Fuhrman nuclear grade of clear cell renal cell carcinoma. *Front Oncol*. 2022;12:961779.
80. Xiong Y, Yao L, Lin J, Yao J, Bai Q, Huang Y, et al. Artificial intelligence links CT images to pathologic features and survival outcomes of renal masses. *Nat Commun*. 2025 Feb 7;16(1):1425.
81. Er H, Lu B, N R, A HH, Np P, Mgb T, et al. Interactive virtual 3D models of renal cancer patient anatomies alter partial nephrectomy surgical planning decisions and increase surgeon confidence compared to volume-rendered images. *Int J Comput Assist Radiol Surg [Internet]*. 2019 Apr [cited 2025 July 19];14(4). Available from: <https://pubmed.ncbi.nlm.nih.gov/30680601/>
82. Amparore D, Piramide F, De Cillis S, Verri P, Piana A, Pecoraro A, et al. Robotic partial nephrectomy in 3D virtual reconstructions era: is the paradigm changed? *World J Urol*. 2022 Mar;40(3):659–70.
83. Michiels C, Khene ZE, Prudhomme T, Boulenger de Hauteclouque A, Cornelis FH, Percot M, et al. 3D-Image guided robotic-assisted partial

- nephrectomy: a multi-institutional propensity score-matched analysis (UroCCR study 51). *World J Urol.* 2023 Feb;41(2):303–13.
84. Yin K, Liu C, Bardis M, Martin J, Liu H, Ushinsky A, et al. Deep learning segmentation of kidneys with renal cell carcinoma. *J Clin Oncol.* 2019 May 20;37(15_suppl):e16098–e16098.
 85. A pilot study investigating the feasibility of using a fully automatic software to assess the RENAL and PADUA score - PubMed [Internet]. [cited 2025 July 19]. Available from: <https://pubmed.ncbi.nlm.nih.gov/35589469/>
 86. Heller N, Tejpaul R, Isensee F, Benidir T, Hofmann M, Blake P, et al. Computer-Generated R.E.N.A.L. Nephrometry Scores Yield Comparable Predictive Results to Those of Human-Expert Scores in Predicting Oncologic and Perioperative Outcomes. *J Urol.* 2022 May;207(5):1105–15.
 87. Wood AM, Abdallah N, Heller N, Benidir T, Isensee F, Tejpaul R, et al. Fully Automated Versions of Clinically Validated Nephrometry Scores Demonstrate Superior Predictive Utility versus Human Scores. *BJU Int.* 2024 June;133(6):690–8.
 88. Zhao T, Sun Z, Guo Y, Sun Y, Zhang Y, Wang X. Automatic renal mass segmentation and classification on CT images based on 3D U-Net and ResNet algorithms. *Front Oncol.* 2023;13:1169922.
 89. Uniformizing Techniques to Process CT Scans with 3D CNNs for Tuberculosis Prediction. In: *Lecture Notes in Computer Science* [Internet]. Cham: Springer International Publishing; 2020 [cited 2025 July 19]. p. 156–68. Available from: https://link.springer.com/10.1007/978-3-030-59354-4_15
 90. Qayyum A, Lalande A, Meriaudeau F. Automatic segmentation of tumors and affected organs in the abdomen using a 3D hybrid model for computed tomography imaging. *Comput Biol Med.* 2020 Dec;127:104097.
 91. He Y, Yang G, Yang J, Ge R, Kong Y, Zhu X, et al. Meta grayscale adaptive network for 3D integrated renal structures segmentation. *Med Image Anal.* 2021 July;71:102055.

92. Karunanayake N, Lu L, Yang H, Geng P, Akin O, Furberg H, et al. Dual-Stage AI Model for Enhanced CT Imaging: Precision Segmentation of Kidney and Tumors. *Tomogr Ann Arbor Mich.* 2025 Jan 3;11(1):3.
93. Toda N, Hashimoto M, Arita Y, Haque H, Akita H, Akashi T, et al. Deep Learning Algorithm for Fully Automated Detection of Small (≤ 4 cm) Renal Cell Carcinoma in Contrast-Enhanced Computed Tomography Using a Multicenter Database. *Invest Radiol.* 2022 May 1;57(5):327–33.
94. Mahmud S, Abbas TO, Mushtak A, Prithula J, Chowdhury MEH. Kidney Cancer Diagnosis and Surgery Selection by Machine Learning from CT Scans Combined with Clinical Metadata. *Cancers.* 2023 June 14;15(12):3189.
95. Zhu XL, Shen HB, Sun H, Duan LX, Xu YY. Improving segmentation and classification of renal tumors in small sample 3D CT images using transfer learning with convolutional neural networks. *Int J Comput Assist Radiol Surg.* 2022 July;17(7):1303–11.
96. Coy H, Hsieh K, Wu W, Nagarajan MB, Young JR, Douek ML, et al. Deep learning and radiomics: the utility of Google TensorFlow™ Inception in classifying clear cell renal cell carcinoma and oncocytoma on multiphasic CT. *Abdom Radiol N Y.* 2019 June;44(6):2009–20.
97. Kadhim DA, Mohammed MA. A comprehensive review of artificial intelligence approaches in kidney cancer medical images diagnosis, datasets, challenges and issues and future directions. *Int J Math Stat Comput Sci.* 2024;2:199–243.