


TÜMÖRLER VE YAPAY ZEKAYA GÜNCEL RADYOLOJİK YAKLAŞIM



Editör
FUNDA DİNÇ



BİDGE Yayınları

**TÜMÖRLER VE YAPAY ZEKAYA GÜNCEL
RADYOLOJİK YAKLAŞIM**

Editör: FUNDA DİNÇ

ISBN: 978-625-372-741-3

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2025-06-25

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltpe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /
Ankara



İÇİNDEKİLER

IMAGING OF HIGH RISK BREAST LESIONS	1
<i>FUNDA DİNÇ</i>	
SOLİD BÖBREK TÜMÖRLERİNDE GÖRÜNTÜLEME	14
<i>TARIK SAĞLAM</i>	
ADRENAL LEZYONLARA YAKLAŞIM	31
<i>SADULLAH ŞİMŞEK</i>	
YAPAY ZEKANIN GÖRÜNTÜLEME TEKNİKLERİNE ENTEGRASYONU: TEKNOLOJİK DÖNÜŞÜM VE UYGULAMA ALANLARI	47
<i>SEDA DEMİR</i>	

BÖLÜM 1

¹IMAGING OF HIGH RISK BREAST LESION

Doç. Dr. Funda Dinç
Muğla Sıtkı Koçman Üniversitesi Tıp Fakültesi
Radyoloji AD,
Orcid: 0000-0002-3979-4413

Introduction

Breast Imaging Reporting and Data System (BI-RADS) has been developed to assist radiologists in risk assessment of breast imaging results and to effectively communicate the findings and their implications to referring physicians and patients. It applies to mammography, ultrasound (US), and magnetic resonance imaging (MRI). BI-RADS classifies breast lesions from categories 0 to 6 based on imaging findings. A biopsy is recommended for BI-RADS category 4 or 5 (1). BI-RADS classification and B classification which can be confused with each other, are different terminologies. Breast biopsy specimens results are classified on a spectrum ranging from B1 (normal) to B5 (malignant), depending on their histological features. In this context, B3 lesions is also known as "high-risk

lesion" or "lesions of uncertain malignant potential" represent a heterogeneous group of several entities that have different levels of risk associated with malignancy (2). Pathological diagnostic variability is common among B3-lesions, which are radiologically categorised as B²IRADS 4 or 5 on breast imaging modalities. The incidence of B3 lesions ranges from 3% to 21%. With worldwide implementation of breast cancer screening programs, detection of these lesions is increasing, and this trend appears to be consistent with the use of advanced imaging technologies (3).

B3 lesions includes atypical ductal hyperplasia (ADH), flat epithelial atypia (FEA), lobular neoplasia (LN), papillary lesions, radial scar/complex sclerosing lesions, and miscenelous lesions such as benign phyllodes tumors (4) (Table). They are considered as having biologically of uncertain malignant potential and progression risk. These lesions are highly heterogeneous as histopathological features and can be classified according to the presence or absence of atypia. The presence of atypia should be noted in reports as it increases the potential for malignancy. Some of B3 lesions are non-obligate precursors of cancer, and up to 35% of lesions can develop into ductal carcinoma in situ (DCIS) and low-grade invasive tumors. Also, high risk lesions may coexist with in situ or invasive breast carcinoma. Furthermore, some of these entities serve as risk indicators of significantly increased future breast cancer risk in various rates. Patients with ADH or lobular neoplasia have 4–10 times higher risk of developing breast cancer (5,6,7). The radiological appearance of this rather heterogeneous group are different from each other. (5).

Atypical Ductal Hyperplasia (ADH)

² Doç Dr Funda Dinç
Muğla Sıtkı Koçman Üniversitesi Tıp Fakültesi Radyoloji AD
0000-0002-3979-4413

ADH shows cytologic and architectural atypia which is restricted to one terminal ductulo-lobular unit (TDLU) and 2 mm or less in maximal extension. Diagnostic distinction from low grade ductal carcinoma in situ (DCIS) is based on size only (8,9). ADH is the most ³frequent diagnosed high-risk breast lesion which is detected approximately 4 of core needle biopsy specimens. Besides, ADH has the highest upgrade rate to malignancy of all the high-risk lesions. Calcifications at mammography are the most common imaging finding of ADH. Although calcifications may vary different morphology and distribution, typically appear amorphous and grouped (Figure 1). ADH, also present as a mass or distortion at mammography and US but generally, the presence of a mass or distortion is due to a coexisting lesion. The most common US finding is an irregular microlobulated mass with mild hypoechogenicity without any posterior acoustic features (10). ADC can be detected both at contrast-enhanced mammography (CEM) and MRI. In both modalities, imaging findings are non-specific but it manifests mostly as nonmass enhancement, less often as a mass at both CEM and MRI (11,12) Upgrade rates of ADH is approximately. 14%, as 20% to DCIS and of 9% to invasive cancer. It has been shown that the method of percutaneous biopsy has impact on upgrade rates. Due to high high upgrade rate to malignancy of ADH, most guidelines recommend surgical excision. Vacuum-assisted excision (VAE) can be considered if lesion is less than 15 mm diameter (2,13,14).

Flat Epithelial Atypia (FEA)

FEA is characterized several layers of mildly atypical monomorphic cuboidal to columnar cells. Despite pure FEA is encountered in 1%–2% of breast biopsies, in 35% of the cases FEA

is found in association with other lesions such as DCIS, LN or tubular carcinoma. FEA likewise ADH most commonly presents with calcifications on mammography. Calcifications are tend to be amorphous or fine pleomorphic and clustered. On ultrasound, FEA may appear as rather irregular, microlobulated, or hypoechoic mass. Imaging findings may be commonly related to concurrent other pathology. FEA may be occult or have non-specific features at MRI and CEM (2,10). Guideline suggestions for FEA varies between follow-up to complete removal with vacuum-assisted biopsy or surgical excision (2,10, 13,14).

Lobular Neoplasia (LN)

Lobular neoplasia is an uncommon lesion with an estimated incidence of 0.5 % to 4 % of benign breast biopsies. LN is a neoplastic proliferation of small dyscohesive epithelial cells originating from the TDLU. Classical LN divides into atypical lobular hyperplasia (ALH) and lobular carcinoma in situ (LCIS) based on the extent within the TDLUs. The extent is <50% of TDLUs in ALH, $\geq 50\%$ in LCIS. LN is considered as a non-obligate precursor of lobular type breast cancer. LN is usually occult on imaging and, therefore, is diagnosed incidentally in specimens. Classical LN usually does not produce calcifications like ADH or FEA. If calcifications are present, they are more often due to an associated entities. LN is regarded to have no typical imaging pattern in all modalities. Classical LN may be seen as mass on US or subtle focal non-mass enhancement on MRI (2,15) (Figure 2). Due to the high relative risk of developing a subsequent invasive breast cancer (4–10%) and high upgrade rates into DCIS or invasive cancer (20%), although treatment options are controversial, surgical excision⁵ is recommended in LNs (2,13,14).

Papillary⁶ lesions (PL)

Papillary lesions have a wide spectrum of histopathological entities including benign papillomas, papillomas with atypia, papillary DCIS, encapsulated and solid papillary carcinomas. The B-classification of PL varies from B3, B4, to B5a or B5c. Papillomas with and without atypia, defined as B3 lesions, will be discussed in this section. Mammography may depict normal findings. On mammography PL may appear as circumscribed mass. Clustered calcification within a circumscribed mass occasionally be seen on mammography. US shows typically as hypoechogenic, circumscribed lesions, which may contain cysts. Sometimes they show vascularization on Doppler US. Typical MRI finding of PLs is as circumscribed, enhancing mass; however, they can also be seen as irregular shaped mass and mass with ill-defined margins (16, 17) (Figure 3). If core needle biopsy yields papilloma without atypia, VAE is sufficient. But, surgical excision is necessary if core needle biopsy or vacuum aspiration biopsy indicate a papilloma with atypia (13,14,18).

Radial scar (RS)

Radial scar is frequently occult on imaging. But, Typical finding of RS is spiculated lesion or structural distortion with or without associated calcifications on mammography. Tomosynthesis help recognition of RS. On ultrasound On ultrasound, RS may be occult, and may appear as parenchymal distortion and/or a hypoechoic mass. RS is presented as spiculated lesion or architectural distortion with or without enhancement. (2,19) The upgrade rate in RS without atypia is 9% and with atypia is 25%

⁶ Doç. Dr Funda DİNÇ

Muğla Sıtkı Koçman Üniversitesi Tıp Fakültesi Radyoloji AD
0000-0002-3979-4413

(20,21). Considering the atypia, method of biopsy VEA or surgical excision can be eligible.

Conclusion

High-risk lesion of the breast represent a heterogeneous group of several entities that have different levels of cancer risk and some are non-obligate precursors of cancer. They show variable risk of increased future breast cancer. Radiological appearance is variable in this heterogeneous group, and the imaging features and upgrade rates of these entities should be well known. While some lesions require VAE or surgical excision, some can be safely monitored with imaging. Management of high risk lesions of breast is influenced by factors as radiological findings, histopathological characteristics, presence of atypia, the method of percutaneous biopsy, the lesion size, and patient factors. Careful consideration of radiologic-pathologic concordance and multidisciplinary approach is required in high risk breast lesions.

Table: Risk factors for upgrading and management of B3 lesions.

<i>B3 Lesion</i>	<i>Upgrade Rate (%)</i>	<i>Upgrade Risk Factors</i>	<i>Management</i>
<i>Atypical Ductal Hyperplasia (ADH)</i>	<i>5–50%</i>	<i>Radio-pathological mismatch Size > 15 mm Age > 50 years Multifocality in the biopsy specimen Small amount of biopsy tissue</i>	<i><15 mm VAE can be considered >15 mm surgical excision</i>
<i>Flat Epithelial Atypia (FEA)</i>	<i>1–16%</i>	<i>Concurrent proliferative lesion Radio-pathological discordance Residual calcification after VAB</i>	<i>No ADH/no risk factors: observation With ADH/risk factors: VAE vs. surgical excision</i>

		<i>Mass lesion</i>	
<i>Lobular Neoplasia (LN)</i>	<i>0–50%</i>	<i>Mass lesion Radio-pathological discordance</i>	<i>CNB diagnosis: VAE VAB diagnosis: observation Radio- pathological discordance: surgical excision</i>
<i>Papillary Lesion (PL) no atypia with atypia</i>	<i>9–13.2% 36–47.8%</i>	<i>Mass or calcification Peripheral lesion site Palpable lump Size>1cm</i>	<i>No atypia:VAE Atypia: surgical excision</i>
<i>Radial Scar (RS)</i>	<i>0–40%</i>	<i>Presence of atypia Small amount of biopsy tissue</i>	<i>No atypia: VAE Atypia: surgical excision</i>

VAB: Vacuum assisted biopsy

VAE: Vacuum-assisted excision

CNB: Core needle biopsy

Figure 1: Magnified image of mammography shows amorphous , coarse heterogeneous clustered calcifications. Histopathological diagnosis is atypical ductal hyperplasia.




Figure 2: Multiple hypoechoic ovoid masses are seen on ultrasound. Core needle biopsy and excision resulted in lobular carcinoma in situ.





Figure 3: Subtracted dynamic contrast enhanced sequence of MRI shows heterogenous enhancing mass irregular. Biopsy revealed papilloma with atypia.



Kaynakça

1. D'Orsi CJ, Sickles EA, Mendelson EB, et al. (2013) ACR BI-RADS® Atlas, Breast Imaging Reporting and Data System. Reston, VA, American College of Radiology; ISBN:155903016X.
2. Elfgren C, Leo C, Kubik-Huch RA, et al. (2023) Third International Consensus Conference on lesions of uncertain malignant potential in the breast (B3 lesions). *Virchows Arch. Jul*;483(1):5-20. doi: 10.1007/s00428-023-03566-x.
3. E.A. Rakha, A.H. Lee, J.A. Jenkins, et al. (2011) Characterization and outcome of breast needle core biopsy diagnoses of lesions of uncertain malignant potential (B3) in abnormalities detected by mammographic screening. *Int J Cancer*, 129 (6) pp. 1417-1424.
4. Rubio IT, Wyld L, Marotti L, et al (2024) European guidelines for the diagnosis, treatment and follow-up of breast lesions with uncertain malignant potential (B3 lesions) developed jointly by EUSOMA, EUSOBI, ESP (BWG) and ESSO. *Eur J Surg Oncol. Jan*;50(1):107292. doi: 10.1016/j.ejso.2023.107292.
5. Catanzariti F, Avendano D, Cicero G. *et al.* (2021) High-risk lesions of the breast: concurrent diagnostic tools and management recommendations. *Insights Imaging* 12, 63. <https://doi.org/10.1186/s13244-021-01005-6>
6. Coopey SB, Mazzola E, Buckley JM et al (2012) The role of chemoprevention in modifying the risk of breast cancer in women with atypical breast lesions. *Breast Cancer Res Treat* 136:627–633. <https://doi.org/10.1007/s10549-012-2318-8>
7. El-Sayed ME, Rakha EA, Reed J, et al. (2008) Predictive value of needle core biopsy diagnoses of lesions of uncertain malignant potential (B3) in abnormalities detected by mammographic

screening. *Histopathology* 53:650–657. <https://doi.org/10.1111/j.1365-2559.2008.03158.x>

8. Nicosia L, Mariano L, Pellegrino G, et al. (2024) Atypical Ductal Hyperplasia and Lobular In Situ Neoplasm: High-Risk Lesions Challenging Breast Cancer Prevention. *Cancers (Basel)*. Feb 19;16(4):837. doi: 10.3390/cancers16040837.

9. Page DL, Dupont WD, Rogers LW, et al (1985) Atypical hyperplastic lesions of the female breast. A long-term follow-up study. *Cancer* 55(11):2698–2708.

10. Harper LK, Carnahan MB, Bhatt AA, et al. (2023) Imaging Characteristics of and Multidisciplinary Management Considerations for Atypical Ductal Hyperplasia and Flat Epithelial Atypia: Review of Current Literature. *Radiographics*. Oct;43(10):e230016. doi: 10.1148/rg.230016.

11. Heller SL, Moy L.(2012) Imaging features and management of high-risk lesions on contrast-enhanced dynamic breast MRI. *AJR Am J Roentgenol*. 198(2):249–255.

12. Perry H, Phillips J, Dialani V, et al. (2019) Contrast-enhanced Mammography: a Systematic Guide to Interpretation and Reporting. *AJR Am J Roentgenol*. 212(1):222–231.

13. Bevers TB, Helvie M, Bonaccio E, et al. (2018) Breast Cancer Screening and Diagnosis, Version 3.2018, NCCN Clinical Practice Guidelines in Oncology. *J Natl Compr Canc Netw*. 16(11):1362–1389.

14. Consensus guideline on concordance assessment of image-guided breast biopsies and management of borderline or high risk lesions. (2016) Columbia, Md: American Society of Breast Surgeons.

15. Tjendra Y. and Susnik B, (2025) Non-invasive Lobular Neoplasia: Review and Updates. In *Seminars in Diagnostic Pathology* (p. 150883). WB Saunders.
16. Eiada R, Chong J, Kulkarni S, Goldberg F, et al (2012) Papillary lesions of the breast: MRI, ultrasound, and mammographic appearances. *AJR Am. J. Roentgenol.* 198, 264–271.
17. D’Archi S, Carnassale B, Sanchez AM, et al. (2025) Navigating the Uncertainty of B3 Breast Lesions: Diagnostic Challenges and Evolving Management Strategies. *J. Pers. Med.* 15, 36. <https://doi.org/10.3390/jpm15010036>
18. Kulka J, Madaras L, Floris G, et al. (2022) Papillary lesions of the breast. *Virchows Arch.* 480, 65–84.
19. Yan P, DeMello L, Baird GL, et al. (2021) Malignancy Upgrade Rates of Radial Sclerosing Lesions at Breast Cancer Screening. *Radiol. Imaging Cancer.* 3, e210036.
20. Rakha E, Beca F, D’Andrea M, et al. (2019) Outcome of radial scar/complex sclerosing lesion associated with epithelial proliferations with atypia diagnosed on breast core biopsy: results from a multicentric UK-based study. *J Clin Pathol* 72(12):800–804
21. Choudhery S, Johnson MP, Larson NB, et al. (2021) Malignant Outcomes of Architectural Distortion on Tomosynthesis: A Systematic Review and Meta-Analysis. *AJR Am. J. Roentgenol.* 217, 295–303.

Giriş

Yüksek çözünürlüklü kesitsel görüntüleme yöntemlerinin artan kullanımıyla, insidental solid renal kitle saptanma sıklığı artmış; doğru tanı için ileri görüntüleme karakterizasyonu gerekliliği doğmuştur. (Differentiation of Solid Renal Tumors with Multiparametric MR Imaging | RadioGraphics t.y.) Malignite riski lezyon boyutuna bağlı olarak değişir; 1 cm'den küçük lezyonlarda bu oran yaklaşık %50 iken, 7 cm ve üzeri kitlelerde %90'ı aşmaktadır.(FRANK vd. 2003)

Gerçek bir renal kitleyi taklit edebilecek hipertrofik Bertin kolonu (Şekil 1), lobar dismorfizm, vasküler anomaliler, travma, hemoraji, enfarktüs veya enfeksiyon gibi diğer nedenlerin dışlanması ilk adımdır; bu bulgular genellikle özgül bir klinik öyküyle ilişkilidir. İkinci adım, lezyonun kistik yapıda olup olmadığının değerlendirilmesidir. Elli yaş üzeri bireylerin yaklaşık yarısında çoğunlukla basit kist niteliğinde olan renal kitleler saptanır.(Silverman vd. 2008) Solid kitleler ise minimal ya da hiç sıvı içermez ve çoğunlukla kontrast tutan vaskülarize dokudan oluşur.(Pedrosa ve Cadeddu 2022; Silverman vd. 2008)

Görüntüleme Yöntemleri

Kistler, kontrastsız BT'de genellikle 0–20 Hounsfield Unite(HU) arasında dansitede ölçülür ve su dansitesine benzer özellik sergiler ve kontrast sonrası belirgin artış göstermez. Ancak, özellikle merkezi yerleşimli ve <1 cm boyutundaki lezyonlarda ışın sertleşmesine bağlı olarak 10–20 HU'luk psödo-enhansman görülebilir.(Silverman vd. 2008; Tappouni vd. 2012)

Kontrastsız BT'de >20 HU atenüasyon gösteren solid renal kitleler benign ya da malign olabilir. Çeşitli çalışmalar, renal hücreli karsinomların (RHK) büyük ölçüde 20–70 HU arasında atenüasyon sergilediğini bildirmiştir. Bu nedenle, kalsifikasyon içermeyen ve bu “tehlike aralığında” yer alan HU değerlerine sahip böbrek kitlelerinin insidental saptanması ileri değerlendirme gerektirir.(O'Connor vd. 2011; Pooler vd. 2012) Kontrastsız BT'de >70 HU homojen atenüasyona sahip renal kitleler vakaların %99'unda hemorajik kisttir; ancak bu kistler <70 HU değerinde de izlenebilir.(Solid Renal Masses: What the Numbers Tell Us | AJR t.y.)

Abdominal Radyoloji Derneği RHK Hastalığa Odaklı Paneli, renal BT protokolünün kontrast öncesi görüntüleme ile başlamasını ve ardından 3 mm kesit kalınlığında nefrografik faz (100–120 sn) görüntülemeyi içermesini önermektedir. Ayrıca, kortikomedüller faz (40–70 sn) ve/veya boşaltım fazı (7–10 dk) opsiyonel olarak eklenebilir. Görüntüleme cerrahi veya girişimsel işlem öncesi planlama amacıyla yapılıyorsa, boşaltım fazının dahil edilmesi tavsiye edilir.(Wang vd. t.y.)

Sonografi(USG) , venöz trombüsün varlığını ve yayılımını değerlendirmede etkili bir görüntüleme yöntemidir. Ayrıca, BT hipovasküler solid tümörler (örneğin, papiller renal hücreli karsinom) ile kistlerin ayırt edilmesinde de yardımcı olabilir.(Ng vd. 2008)

Çoğu RHK 3 cm'den küçük olduğunda hiperekoik özellik gösterebilir; ancak bu bulgu patognomonik değildir, çünkü anjiyomiyolipom(AML) ile benzer bir görünüm sergileyebilir ve ayırıcı tanıyı zorlaştırabilir.(Sidhar vd. 2016) Ayrıca, onkositomda görülen ve büyük ölçüde değişkenlik gösteren USG bulguları, onkositomu RHK'den güvenilir şekilde ayırt edemez.(Goiney vd. 1984) Genel olarak, tümörün ekojenitesi histolojik alt tipler arasında ayırım yapmaz ve benign lezyonları malign lezyonlardan güvenilir şekilde ayırt edemez.(Sidhar vd. 2016)

¹ Uzman Doktor,SBÜ Gazi Yaşargil Eğitim ve Araştırma Hastanesi,Radyoloji Kliniği, Diyarbakır, Orcid: 0000-0002-0877-9042, tariksaglamitf@gmail.com

BT, Amerikan Radyoloji Koleji Uygunluk Kriterleri'ne göre belirsiz böbrek kitlelerinin ilk karakterizasyonunda MRG'ye kıyasla biraz daha yüksek bir derecelendirmeye sahiptir (ACR Uygunluk Kriterleri: BT için 9, MRG için 8).(Heilbrun vd. 2015b)

Kontrastsız BT, iyotlu kontrast madde uygulanmadan önce böbrek kitlesinin bazal dansitesini belirleyerek kontrast sonrası dansite artışını saptar ve ölçer. Ayrıca, kontrastlı BT'de fark edilmesi zor olabilen makroskobik yağ ve kalsifikasyonun tespiti açısından da önem taşır.(Schieda vd. 2015)

Böbrek kitlesinde makroskopik yağ varlığı, AML tanısını destekler. İnce kesitli (1,5–3 mm) kontrastsız BT görüntülerinin yeniden yapılandırılması, daha kalın kesitlerde hacim ortalaması nedeniyle gizlenebilecek az miktardaki yağın tespiti açısından intralezyonel makroskopik yağın varlığını doğrulamak için gereklidir.(Renal angiomyolipoma: a radiological classification and update on recent developments in diagnosis and management | Abdominal Radiology t.y.)

Toplu yağın doğru şekilde tanımlanması, benign neoplazmlar olan AML'lerin tanınmasına yardımcı olur ve özellikle küçük boyutlu lezyonlarda gereksiz müdahale veya cerrahiden kaçınılmasını sağlar. Öte yandan, solid lezyonlardaki kalsifikasyon RHK'de daha yaygın olup, tedavi edilmemiş AML'lerde son derece nadirdir..(Hakim vd. 2016)

Kortikomedüller faz, kontrast maddenin renal korteksin proksimal kıvrımlı tübüllerinde ve Bertin kolonlarında bulunduğu, korteks ile medulla arasında maksimum kontrast farkının gözlemlendiği zaman diliminde elde edilir.(Yuh ve Cohan 1999) Zamanlama, kontrast enjeksiyonundan yaklaşık 30–40 saniye sonradır ve bu süre, kurumsal tercihlere ve kullanılan tarayıcı tipine bağlı olarak ampirik biçimde ya da bolus izleme yazılımı aracılığıyla belirlenebilir. Kortikomedüller fazının başlıca kullanım alanı, RHK alt tiplerinin zamana bağlı kontrastlanma özelliklerine göre sınıflandırılmasıdır. Ayrıca bu faz, renal arteriyel vasküler yapının detaylı değerlendirilmesini sağlar (embolizasyon veya cerrahi planlama için yol haritası olarak) ve tümör trombüsünü belirginleştirerek potansiyel renal ven invazyonunu açıkça ortaya koyar.(Journal of Computer Assisted Tomography t.y.)

Nefrografik faz, kontrast maddenin Henle kulpu ve toplayıcı kanallara ulaştığı zaman dilimi olarak tanımlanır. Bu aşamada, hem renal korteks hem de medulla homojen ve düzgün bir şekilde kontrastlanır.(Yuh ve Cohan 1999) Zamanlama, kontrast enjeksiyonundan yaklaşık 90 ila 120 saniye sonradır. Nefrografik faz, iki temel nedenle renal kitle BT protokolünün ana fazını oluşturur: (1) Nefrografik fazı, kistik renal kitlelerin saptanmasında en hassas fazdır. Aynı zamanda, kistik lezyonların iç kontrastlanmasının değerlendirilmesinde de en duyarlı faz olarak kabul edilir. Ayrıca, bu fazı tümör trombüsünün, özellikle renal ven ve inferior vena kavaya olan yayılımının gösterilmesinde potansiyel olarak değerlidir.(Shetty vd. 2004)

Düşük yoğunluklu bileşenler içeren ve yoğunluğu -10 HU'nun altında ölçülen bir böbrek kitlesi, AML olarak değerlendirilmelidir.(Davenport vd. 2011) -10 ile +20 HU arasında ölçülen renal kistik kitleler (hem kontrastsız hem kontrastlı BT'de), su attenuasyonu ile uyumludur. Ancak bir kistin güvenle tanımlanabilmesi için bu kitlelerin aynı zamanda düzgün, belirgin olmayan duvarlara ve iç yapıda homojen görünüme sahip olması gerekir. Solid berrak hücreli RHK'lerin küçük bir kısmı da -10 ile +20 HU arasında ölçülebilir; ancak bu lezyonlar genellikle düzensiz sınırlara sahip ve heterojen yapıdadır.(Hodgdon vd. 2015) Portal venöz faz kontrastlı BT görüntülerinde, benign kist tanısı için 30 HU ve altındaki eşik değerinin kullanılması daha güvenli kabul edilmektedir.(Agochukwu vd. 2017)

Kontrastsız BT'de 20–70 HU veya tek fazlı kontrastlı BT'de >30 HU olarak ölçülen bir böbrek lezyonu, atenüasyon değerlerinin RHK ile örtüşmesi nedeniyle belirsiz kabul edilir. Solid bir neoplazm ile hemorajik ya da proteinli bir kist arasındaki ayrımı yapabilmek için, kontrastlanmanın varlığını değerlendirmek amacıyla böbrek kitle protokolüne uygun BT veya MRG ile ileri görüntüleme gereklidir.(Krishna vd. 2020)

Kontrastsız BT'de 70 HU veya daha yüksek atenüasyona sahip, kalsifiye olmayan homojen bir böbrek kitlesi, hemorajik ya da proteinli kist olarak kabul edilir.(Jonisch vd. 2007)

Kontrastlı BT’de , kontrastsız BT’deki bazal attenuasyonla karşılaştırıldığında 20 HU veya daha fazla attenuasyon artışı kontrast tutulumunu gösterir; buna karşılık 10 HU veya daha az fark, kontrast tutulumu olmadığını gösterir.(Israel ve Bosniak 2005)

10–20 HU arasındaki kontrast artışı belirsiz olarak değerlendirilir ve genellikle başka bir kesitsel görüntüleme yöntemiyle doğrulanması gerekir. Kontrast tutulumunu değerlendirmek amacıyla attenuasyon ölçümleri nefrografik fazda yapılmalıdır; çünkü bazı papiller tümörler yavaş ve ilerleyici kontrast tutulum gösterebilir ve bu durum, kortikomedüller ya da portal venöz fazda yapılan ölçümlerde 20 HU’nun altında attenuasyon farkı ile yanlışlıkla belirsiz ya da kontrast tutmayan lezyonlar olarak sınıflandırılmalarına neden olabilir..(Dilauro vd. 2016)

Renal kitlelerin değerlendirilmesinde MRG, BT ile karşılaştırılabilir bir tanısal değere sahiptir. MRG’nin daha yüksek kontrast çözünürlüğü, lezyonun iç yapısının-kistik ya da solid oluşu, septa varlığı ve hemoraji gibi özelliklerin-daha ayrıntılı şekilde değerlendirilmesine olanak tanır. T1 ağırlıklı dış faz görüntüleme, AML’de az miktardaki makroskopik yağ dokusunun tespitinde daha duyarlıdır; bu durum, dış faz görüntülerde görülen hint mürekkebi artefaktı ya da Dixon tabanlı çekimlerden elde edilen sadece yağ (fat-only) rekonstrüksiyonları ile doğrudan gözlemlenebilir.(Small (<1 cm) incidental echogenic renal cortical nodules: chemical shift MRI outperforms CT for confirmatory diagnosis of angiomyolipoma (AML) | Insights into Imaging t.y.)

Böbrek MRG protokolü; aksiyel veya koronal düzlemde iki boyutlu (2D) T2 ağırlıklı görüntüler, aksiyel düzlemde faz içi ve faz dışı 2D T1 ağırlıklı görüntüler, kontrast madde uygulaması öncesi ve sonrası elde edilen aksiyel ve/veya koronal düzlemde üç boyutlu (3D) T1 ağırlıklı yağ baskılanmış görüntüler ile böbrek kitlelerinin ayrıntılı karakterizasyonu amacıyla aksiyel difüzyon ağırlıklı(DAG) görüntülemeyi içermelidir .BT veya manyetik rezonans görüntüleme (MRG) ile yapılan değerlendirmelerin temel amacı, böbrek kitlelerini karakterize etmek ve klinik yönetimi yönlendirecek bilgiler sağlamaktır. Yapılan çalışmalarda, belirsiz karakterdeki solid böbrek kitlelerinin yaklaşık %20’sinin nihai tanısının iyi huylu olduğu ve özellikle küçük (<4 cm) boyuttaki kitlelerde benign olma olasılığının daha yüksek olduğu gösterilmiştir.(2017 AUA Renal Mass and Localized Renal Cancer Guidelines: Imaging Implications | RadioGraphics t.y.; Heilbrun vd. 2015a)

BT için geçerli olan “altın kurallar”, MRG için de geçerlidir. T2 ağırlıklı görüntülerde beyin omurilik sıvısına benzer sinyal yoğunluğu gösteren, iyi sınırlı ve homojen renal kitleler benign kist olarak kabul edilir . Kontrastsız MRG’de, T1 ağırlıklı görüntülerde belirgin hiperintens (normal parankim sinyalinden yaklaşık 2,5 kat daha yüksek) bir lezyon genellikle hemorajik proteinöz kist olarak değerlendirilir.(Kim vd. 2017)

BT ve MRG’yi karşılaştıran önceki çalışmalar, cerrahi gerektiren renal tümörlerin saptanmasında her iki yöntemin de benzer tanısal yeterliliğe sahip olduğunu göstermiştir.(Comparison of 16-MDCT and MRI for Characterization of Kidney Lesions | AJR t.y.) Ancak, çapı ≤ 20 mm olan tümörlerde, yağ baskılı kontrastlı MRG sekanslarının, kontrastlı BT’ye kıyasla daha yüksek duyarlılığa sahip olduğu gösterilmiştir.(Combined gadolinium-enhanced and fat-saturation MR imaging of renal masses. | Radiology t.y.)

Malig Solid Tümörler

Renal Hücreli Karsinom

Renal hücreli karsinom erişkinlerde görülen solid renal tümörlerin yaklaşık %90’ını oluşturan en yaygın malign epiteliyal tümördür. Tanı yaşı genellikle ortalama 65’tir ve olguların çoğu erkek hastalardan oluşur.(Kidney Cancer in: Journal of the National Comprehensive Cancer Network Volume 9 Issue 9 (2011) t.y.)

Berrak hücreli Tip RHK

Berrak hücreli renal hücreli karsinom , RHK’nin en sık görülen alt tipidir ve olguların %65–80’ini oluşturur.(Cheville vd. 2003; Ramamurthy vd. 2015)

Olguların yaklaşık %95'inde berrak hücreli RHK sporadik olarak gelişir; kalan %5'lik kısmı ise von Hippel–Lindau hastalığı ve tüberoz skleroz gibi herediter sendromlarla ilişkilidir.(Gurel vd. 2013) Berrak hücreli tümörler, esas olarak ekspansif büyüme paterni gösterir ve proksimal kıvrımlı tübül epitelinin köken alır.(Polascik, Bostwick, ve Cairns 2002) Makroskopik olarak lipid açısından zengin içerikleri nedeniyle altın sarısı bir görünüme sahiptir.(Prasad vd. 2006)

MR görüntülemesinde, berrak hücreli karsinomlar tipik olarak hiperintens ve sıklıkla nekroz, kistik dejenerasyon ve/veya hemorajiye bağlı olarak heterojen yapıda izlenir.(Muglia ve Prando 2015) (Şekil 2) T1 ağırlıklı görüntülerde, genellikle renal parankim ile benzer ya da hipointens gözüktür.(Prasad vd. 2006)

Berrak hücreli RHK'ler hiper vasküler tümörlerdir; arteriyel fazda sıklıkla heterojen kontrast tutulum gösterirler ve diğer RHK alt tiplerine kıyasla daha belirgin kontrastlanırlar. Bu özellik, RHK alt tiplerinin ayırımında yardımcı bir kriter olarak kullanılabilir. Berrak hücreli RHK'lerin, onkositomalar ve anjiyomiyolipomalar gibi hipervasküler benign kitlelerden ayırt edilmesi hâlâ önemli bir tanısal zorluktur.(Hötter vd. 2017)

Berrak hücreli karsinomların yaklaşık %60'ında görülen bir diğer belirgin özellik, lezyon içi mikroskopik yağ varlığıdır. Bu durum, kimyasal kayma görüntülemesinde dış faz görüntülerde, iç faz görüntülere kıyasla sinyal intensitesinde azalma şeklinde izlenebilir. %25'ten fazla sinyal kaybı, mikroskopik yağ varlığı açısından prediktif olabilir.(Hötter vd. 2017; Karlo vd. 2013; Muglia ve Prando 2015) Santral nekroz, berrak hücreli RHK'lerde sık görülen bir özelliktir. T1 ağırlıklı görüntülerde kitlenin merkezinde homojen hipointens alan olarak izlenirken, T2 ağırlıklı görüntülerde orta-yüksek sinyal intensitesi gösterir ve kontrast madde uygulamasından sonra kontrast tutmaz. (Gurel vd. 2013)

Berrak hücreli RHK'ler, özellikle renal ven ve inferior vena kava olmak üzere damar invazyonuna eğilimlidir; tümörlerin yaklaşık %45'inde bu durum görülür ve tümör trombozuna yol açabilir. Bu nedenle, vasküler invazyon ve yayılımın değerlendirilmesi klinik açıdan büyük önem taşır.(Bissada vd. 2003; Prasad vd. 2006)

Yüksek tümör derecesi; daha büyük tümör boyutu, lezyon içi nekroz, retroperitoneal vasküler kollaterallerin varlığı, renal ven trombozu ve tümör kapsülünün bütünlüğünün bozulması ile korelasyon göstermektedir.(Gurel vd. 2013)

Tümör psödokapsülü , hem T1 hem de T2 ağırlıklı görüntülerde izlenebilir ve genellikle büyüyen tümörün komşu renal parankimi baskılamasına bağlı olarak geliştiği düşünülmektedir. Bu psödokapsülün bütünlüğünün bozulması, perirenal yağ dokusuna invazyon (ileri evre) ve daha yüksek nükleer derece ile korelasyon göstermektedir.(Roy vd. 2005)

Fuhrman derecesi arttıkça görünür diffüzyon katsayısı(ADC) değerlerinde azalma eğilimi olduğu bildirilmiştir. Bu durum, DAG'ın berrak hücreli RHK'lerin agresifliğini göstermede ve tümör derecesini öngörmede yardımcı olabileceğini düşündürmektedir.(Cornelis vd. 2015; Parada Villavicencio, Mc Carthy, ve Miller 2017; Ramamurthy vd. 2015)

Papiller ve kromofob RHK'lerle karşılaştırıldığında, berrak hücreli karsinomlar daha semptomatiktir, genellikle daha ileri evrede tanı alırlar ve metastatik olma olasılıkları daha yüksektir. Metastatik RHK olgularının %94'ünü berrak hücreli tip oluşturur ve bu metastazlar en sık akciğerlere yayılım gösterir.(Amin vd. 2002; Cheville vd. 2003; Hoffmann vd. 2008)

Tipik berrak hücreli RHK, küçük renal kitlelerin görüntüleme spektrumunun bir ucunu oluşturur. Bu tümörler genellikle T2-ağırlıklı görüntülerde izointens veya hiperintens görünüm sergiler ve kortikomedüller fazda yoğun, sıklıkla heterojen kontrast tutulum gösterir.(Diaz de Leon vd. 2019)

T2-ağırlıklı görüntülerde hiperintens izlenen küçük renal kitlelerde, berrak hücreli RHK'yi onkositomalar veya kromofob RHK'ler gibi diğer lezyonlardan ayırt edebilmek için mikroskopik yağ varlığının değerlendirilmesi önemlidir. Mikroskopik yağ, genellikle berrak hücreli RHK lehine bir bulgu olup, dış faz görüntülerde sinyal kaybı ile ortaya çıkabilir. Mikroskopik yağ, hücre içi (intrasisitoplazmik) lipid

ve/veya glikojen birikiminin sonucudur; histolojik incelemede lipid açısından zengin berrak hücrelerin görülmesi nedeniyle “berrak hücreli” adı buradan gelir. Mikroskopik yağ, genellikle berrak hücreli RHK’nin kontrast tutan bileşenlerinde bulunur. AML dışı küçük renal kitleler arasında mikroskopik yağ en sık berrak hücreli RHK’de görülür, ancak nadiren diğer histolojik alt tiplerde de ortaya çıkabilir.(Renal Mass Imaging with MRI Clear Cell Likelihood Score: A User’s Guide | RadioGraphics t.y.)

Berrak hücreli RHK’nin DAG özellikleri, benign renal kitlelerle örtüşebilir. Ancak genellikle, berrak hücreli RHK’ler ADC açısından, yağdan fakir AML veya papiller RHK’ye kıyasla daha yüksek ADC değerleri gösterir. Bu nedenle DAG, ayırıcı tanıda yardımcı olabilir fakat tek başına yeterli değildir.(Karlo vd. 2013)

Papiller Tip RHK

Papiller karsinomlar, renal hücreli karsinomların ikinci en yaygın alt tipidir ve olguların %10–15’ini oluşturur.(Cheville vd. 2003; Leroy vd. 2002) Papiller renal hücreli karsinomlar olguların %4’ünde bilateral, %23’ünde ise multifokal olarak görülür.(Amin vd. 2002) Papiller karsinomlar, berrak hücreli karsinoma kıyasla genellikle daha iyi prognoza sahiptir ve daha olumlu klinik sonuçlar gösterir; yaklaşık %90 olan beş yıllık sağkalım oranı ile daha yüksek bir sağkalım beklentisi sunar.(Amin vd. 2002; Cheville vd. 2003; Yoshimitsu vd. 2006) Makroskopik olarak, papiller RHK’ler sıklıkla hemoraji, nekroz ve kistik dejenerasyon alanları içerir.(Prasad vd. 2006) Sarkomatoid diferansiyasyon, papiller RHK olgularının yaklaşık %5’inde görülebilir.(Gurel vd. 2013)

MRG’de 3 cm’den küçük, iyi sınırlı, homojen ve periferik yerleşimli bir tümör olarak izlenir. Tümör çapı 4 cm’yi aştığında ise hemoraji, kalsifikasyon ve nekroz gibi nedenlerle iç heterojenite izlenebilir.(Muglia ve Prando 2015; Prasad vd. 2006) Papiller RHK’ler genellikle T2 hipointens ve hipovasküler yapıda olup, kontrast madde sonrasında progresif kontrast tutulum sergiler.(Cornelis vd. 2015; Rosenkrantz vd. 2013)(Şekil 3)

Papiller RHK’ler hemosiderin içerebilir ve bu durum, kimyasal kayma görüntülemesinde iç faz görüntülerde dış faz görüntülere kıyasla sinyal kaybına neden olan alanlar şeklinde izlenebilir.(Prasad vd. 2006)

Papiller karsinomların görüntüleme görünüşleri, berrak hücreli RHK’lerden farklılık gösterir. Berrak hücreli karsinomlar klasik olarak T2-ağırlıklı görüntülerde daha yüksek sinyal intensitesi gösterir, hipervaskülerdir ve içerdiği yağ nedeniyle dış faz görüntülerde iç faz görüntülere kıyasla sinyal düşüşü izlenebilir. Öte yandan, yağ içeriği düşük AML’ler de T2-ağırlıklı görüntülerde düşük sinyal intensitesi gösterse de bu lezyonlar kontrast madde uygulamasından sonra belirgin kontrast tutulum sergiler. Buna karşılık, papiller RHK’ler hipovaskülerdir ve kontrast sonrası progresif kontrast tutulum gösterir.(Ramamurthy vd. 2015)

Nadiren, papiller RHK’lerde interstisyel makrofajlarda biriken kolesterolden kaynaklanan mikroskopik yağ odakları veya hücre içi (intrasisitoplazmik) yağ birikimi şeklinde yağ içerikleri görülebilir.(Muglia ve Prando 2015)

Papiller RHK’lerin, berrak hücreli RHK’lere kıyasla daha düşük ADC değerleri gösterdiği bildirilmiştir; ancak bu değerlerde örtüşme olabileceği için ayırıcı tanıda diğer MRG bulguları da mutlaka dikkate alınmalıdır.(Allen vd. 2014; Wang vd. 2010)

Kromofob Tip RHK

Kromofob karsinomlar, renal hücreli karsinomların %4–11’ini oluşturur ve üçüncü en sık görülen alt tiptir.(Cheville vd. 2003; Gurel vd. 2013) Bu tümörler, berrak hücreli RHK’lere kıyasla genellikle daha iyi bir prognoz ile ilişkilendirilir ve yaklaşık %78–93 oranında beş yıllık sağkalım oranına sahiptir.(Klatte vd. 2008; Volpe vd. 2012) Kromofob RHK olgularının yaklaşık %7’sinde metastaz gelişir ve bu metastazlar en sık karaciğer ve akciğerlere yayılım gösterir.(Gurel vd. 2013)

Makroskopik olarak, kromofob RHK'ler solid, iyi sınırlı, açık kahverengi renkte ve hafif lobüle yüzeyli tümörlerdir.(Prasad vd. 2006) Kromofob RHK'ler, onkositomalarla aynı kökene sahiptir ve her iki tümör tipi histolojik ve görüntüleme özellikleri açısından örtüşen benzerlikler gösterir.(Rosenkrantz vd. 2010)

MRG görüntülemesinde kromofob tümörlerle ilişkili özgün bir bulgu bulunmamakla birlikte, bu lezyonlar genellikle iyi sınırlı ve homojen yapıdadır. T2-ağırlıklı görüntülerde kromofob RHK'lerin sinyal intensitesi belirgin değişkenlik gösterebilir; ancak genellikle orta düzeyden düşük düzeye kadar sinyal intensitesi sergilerler.(Muglia ve Prando 2015) Kistik değişim ve santral nekroz, hatta büyük tümörlerde bile, kromofob RHK'lerde nadir görülen özelliklerdir.(Gurel vd. 2013)

Kontrastlı görüntülerde, kromofob RHK'lerin kontrast tutulum paterninin “orta dereceli” olduğu görülmektedir; yani, berrak hücreli RHK'lere göre daha az, papiller karsinomlara göre ise daha fazla kontrastlanma gösterirler.(Kay ve Pedrosa 2018)

Kromofob RHK'ler, olguların %30–40'ında merkezi yıldız şeklinde skar ve tekerlek teli şeklinde kontrast tutulum gösterebilir. Ancak bu bulgular spesifik değildir; çünkü onkositomalar da benzer özellikler sergileyebilir.(Rosenkrantz vd. 2010)

Segmental kontrast tutulum inversiyonu, spesifik olmayan ve onkositomalarda da görülebilen bir başka görüntüleme bulgusudur. Bu özellik, kontrast madde uygulamasını takiben erken faz görüntülerde belirgin kontrast tutulum gösteren alanların geç faz görüntülerde daha az kontrastlanması, buna karşılık erken fazda hipovasküler görünen diğer alanların geç fazlarda progresif kontrast tutulum sergilemesi şeklinde tanımlanır.(Allen vd. 2014; Woo vd. 2013)

Benign Solid Tümörler

Anjiyomyolipom

Anjiyomyolipoma, en sık karşılaşılan benign solid renal tümörlerden biridir.(Jinzaki vd. 2014) Bu lezyonlar en sık 40–60 yaşları arasında görülür ve kadınlarda daha yüksek prevalansa sahiptir.(Woo ve Cho 2015)

Song ve arkadaşları, renal anjiyomyolipomaları yağ içeriğine göre üç alt tipe ayıran yeni bir radyolojik sınıflama sistemi önermiştir: yağdan zengin AML, yağdan fakir AML ve yağ görünmeyen AML. Bu sınıflama, BT veya MRG ile nicel olarak belirlenen yağ miktarına dayanır.(Song, Park, ve Park 2016; Park 2017)

Yağ baskılama sekansları esas olarak makroskopik yağı saptamada kullanılsa da lezyon ile referans bir yapı (örneğin dalak veya böbrek) arasındaki ince sinyal yoğunluğu farklarının oranlar yoluyla analiz edilmesi sayesinde küçük miktardaki yağ varlığının gösterilmesinde de fayda sağlayabilir. Yağdan fakir AML'lerin, çift eko kimyasal kayma görüntülemesinde daha yüksek sinyal intensite indeksi ($\frac{SI_{in-phase} - SI_{opposed-phase}}{SI_{in-phase}} \times 100$) ve daha düşük tümör-dalak sinyal intensite oranı gösterdiği bildirilmiştir. Ayrıca, bu lezyonlar kontrast madde uygulamasından sonra erken ve geç faz görüntüleri arasında yüksek sinyal intensite oranı sergiler.(Farrell vd. 2015; Oliva vd. 2009)

- **Yağdan zengin AML:** BT'de –10 HU veya daha düşük ölçülen lezyonlar.
- **Yağdan fakir AML:** BT'de –10 HU'nun üzerinde HU değeri olup, tümör-dalak sinyal oranı < 0.71 ya da sinyal intensite indeksi $> \%16.5$ olan lezyonlar.
- **Yağ görünmeyen AML:** BT'de –10 HU'nun üzerinde olup, tümör-dalak oranı ≥ 0.71 ve sinyal indeksi $\leq \%16.5$ olan lezyonlar.

Song ve ark.(Song vd. 2016) ile Park(Park 2017) , BT ve MRG ile çoğunluğu 3 cm'den küçük olan küçük renal kitleleri incelemişlerdir. Bu çalışmalarda, dış faz görüntülerde yağdan fakir AML'lerde görülen

sinyal düşüşünün daha sınırlı ve fokal olduğu, berrak hücreli RHK'lerde ise sinyal düşüşünün daha yaygın ve daha az belirgin olduğu rapor edilmiştir.

Kontrastsız BT, yağdan fakir AML ile berrak hücreli RHK'yi ayırt etmede yardımcı olabilir; çünkü yağdan fakir AML'ler genellikle hiperattenu, berrak hücreli RHK'ler ise hipoattenu görünüm sergiler.(Jeong vd. 2016; Park 2017)

T2-ağırlıklı MRG, yağdan fakir AML ile berrak hücreli RHK'yi ayırt etmede faydalıdır. Bu sekansla elde edilen görüntülerde, yağdan fakir AML'ler genellikle hipointens görünüm sergilerken, berrak hücreli RHK'ler hiperintens olarak izlenir. Bu sinyal farkı, iki lezyonun noninvaziv şekilde ayırımında önemli bir tanısal kriter olarak değerlendirilebilir.(Jeong vd. 2016; Park 2017)

DAG, yağdan zengin AML ile berrak hücreli RHK'nin ayırıcı tanısında da faydalı bir görüntüleme yöntemidir. Yağdan fakir AML, DAG'da hiperintens görünüm sergiler ve düşük ADC değerlerine sahiptir. Buna karşılık, berrak hücreli RHK genellikle DAG'da hipointens görünür ve yüksek ADC değerleri gösterir. Bu karşıtlık, lezyonların hücresel yoğunluk ve doku yapısı farklarını yansıtmakta olup ayırıcı tanıda önemli bir rol oynar.(Park 2017; Tanaka vd. 2011)

Kontrastlı MRG, yağdan fakir AML ile berrak hücreli RHK'yi ayırt etmede DAG kadar faydalı değildir; çünkü her iki tümör de heterojen kontrast tutulum gösterir ve bu kontrastlanma paternleri büyük ölçüde örtüşür. Bu nedenle, kontrastlı MRG ile yapılan değerlendirmelerde ayırt edici özellikler sınırlı olabilirken, DAG lezyonların hücresel yapısına dayalı olarak daha belirgin farklar sunar.(Park 2017; Sasiwimonphan vd. 2016)

AML'ler günümüzde perivasküler epiteloïd hücre tümörleri (PEComa) ailesinin bir üyesi olarak kabul edilmekte olup, değişken patolojik, görüntüleme ve klinik özellikler gösteren heterojen bir tümör grubunu oluştururlar. AML'ler tipik olarak değişken oranlarda dismorfik kan damarları, düz kas elemanları ve olgun adipöz dokudan oluşur.(Farrell vd. 2015; Jinzaki vd. 2014)

AML'lerin yaklaşık %80'i sporadik ve tesadüfen saptanan lezyonlardır; kalan %20'si ise tüberoz skleroz kompleksi ile ilişkilidir ve aynı zamanda lenfanjiyomyomatosis ile de ilişkili olabilir.(Jinzaki vd. 2014) Tüberoz skleroz kompleksi ile ilişkili AML'lere bir örnek, nadir görülen ve çok az veya hiç yağ hücresi içermeyen epiteloïd AML'dir.(Farrell vd. 2015; Jinzaki vd. 2014)

AML'lerin %10'unda lezyon çapı 4 cm'nin üzerine çıktığında, potansiyel olarak yaşamı tehdit edebilecek kanama riski artar; bu durum Wunderlich sendromu olarak bilinir.(Steiner vd. 1993)

Tümör büyüdükçe AML'ye gelen kan akımı artar, bu da damar dilatasyonuna ve psödoanevrizma oluşumu ile büyümesine neden olur. Ayrıca, rüptüre olmuş tümörlerde genellikle 5 mm'den büyük psödoanevrizmalar saptanmıştır; bu da anjiyografide görülen psödoanevrizmaların hemorajik karakterde olduğunu düşündürmektedir.(Yamakado vd. 2002)

Nadiren, büyük AML'ler belirgin şekilde ekzofitik olabilir ve perinefrik liposarkomlardan ayırt edilmesi zorlaşabilir. Ekzofitik bir AML'yi düşündüren özellikler arasında iyi sınırlı bir lezyon, renal parankime ait keskin sınırlı defektin varlığı (böbrek kökenini işaret eden) ve genişlemiş damarların mevcudiyeti yer alır.(Israel vd. 2002; Israel ve Bosniak 2008)

MRG görüntülemesinde, klasik AML'ler yağ içerikleri nedeniyle T1 ağırlıklı görüntülerde yüksek sinyal intensitesi gösterir. Makroskopik yağ varlığı, frekans-selektif yağ baskılamalı sekanslarda sinyal intensitesinin baskılanmasıyla ve opposed-phase görüntülerde india ink artefaktı ile kolaylıkla fark edilebilir.(Israel vd. 2005; Jinzaki vd. 2014)(Şekil 4)

India ink artefaktı, aynı görüntüleme vokselinde hem yağ hem de su protonlarının bulunması nedeniyle oluşan sinyal kaybıdır. Bu artefakt, yağ ve su dokularının sınırlarında keskin siyah bir çizgi olarak izlenir ve genellikle dış faz görüntülerde görülür.(Israel vd. 2005)

T2-ağırlıklı görüntülerde sinyal intensitesi, lezyonun içerdiği yağ miktarına bağlı olarak değişir. Yüksek yağ içeriğine sahip AML'ler T2-ağırlıklı görüntülerde nispeten hiperintens görünürken, daha düşük yağ içeriğine sahip lezyonlar hipointens olarak izlenir.(Hindman vd. 2012)

Bazı AML'ler perinefrik alana geniş şekilde yayılım gösterip böbreğe dar bir tabanla tutunurlar; bu durum, görüntülemelerde “mantara benzer şekil görünümü” (mushroom shape appearance) olarak tanımlanır.(Allen vd. 2014)

Olgu sunumlarında, kalsifikasyon veya ossifikasyonla birlikte makroskopik yağ içeren RHK'ler bildirilmiştir .(Hélénon vd. 1993; Strotzer, Lehner, ve Becker 1993) MRG, kalsifikasyonları BT kadar iyi gösteremese de, bu tür lezyonlar oldukça nadirdir. Ayrıca RHK'ler, perinefrik ve renal sinüs yağ dokusunu çevreleyerek AML'leri taklit edebilir.(Differentiation of Solid Renal Tumors with Multiparametric MR Imaging | RadioGraphics t.y.)

Yağdan fakir (lipid-poor) AML, patolojik olarak yüksek büyütme alanında (high-power field) %25'ten fazla yağ hücresi içermeyen AML olarak tanımlanır.(Farrell vd. 2015; Jinzaki vd. 2014) Yağdan fakir (lipid-poor) AML'ler, neredeyse tamamen düz kas dokusu ve düzensiz damar yapılarından oluşur.(Jinzaki vd. 2014)

MR görüntülemelerde, yağdan fakir AML'ler genellikle homojen yapıdadır ve bol miktarda düz kas içermeleri nedeniyle T2-ağırlıklı görüntülerde düşük sinyal intensitesi, T1-ağırlıklı görüntülerde ise yüksek sinyal intensitesi gösterir . Bu lezyonlar tipik olarak erken fazda yoğun kontrast tutulum ve ardından washout paterni sergiler; ancak bu kontrastlanma paterni değişkenlik gösterebilir. Ayrıca dış faz görüntülerde iç faz görüntülere kıyasla sinyal kaybı göstererek mikroskobik yağ varlığını da ortaya koyabilirler .(Hindman vd. 2012; Israel vd. 2005; Israel ve Bosniak 2008; Woo ve Cho 2015)

AML'ler, diffüzyon kısıtlılığı gösterir ve buna karşılık gelen düşük ADC değerleri ile karakterizedir. Ancak diffüzyon kısıtlılığı AML'ye özgü değildir; malign lezyonlar da benzer şekilde sınırlı difüzyon gösterebilir. Bu nedenle, tek başına difüzyon bulgularına dayanarak kesin tanı konulması mümkün değildir.(Allen vd. 2014)

Klasik (yağdan zengin) formlarının aksine, yağdan fakir AML'ler genellikle görünür makroskopik veya mikroskobik yağ içermez. Bu lezyonlar tipik olarak homojen şekilde T2-hipointens görünür (papiller RHK'lere benzer şekilde), ancak anjiyomatöz bileşenleri nedeniyle kortikomedüller fazda yoğun kontrast tutulum gösterirler (papiller RHK'lerden farklı olarak). Ne yazık ki, atipik bazı berrak hücreli RHK'ler de benzer görüntüleme özellikleri sergileyebilir. Yağdan fakir AML tanısını destekleyen iki ek görüntüleme bulgusu ise sınırlı difüzyon ve artmış ADER (apparent diffusion enhancement ratio) değeridir.(Wilson vd. 2021)

Her ne kadar berrak hücreli RHK ve yağdan fakir AML her ikisi de gecikmiş faz görüntülemelerde hipointens hale gelebilse de, yağdan fakir AML genellikle bu hipointensiteyi daha belirgin şekilde gösterir. Bu nedenle, ADER (apparent diffusion enhancement ratio) değerinin 1.5 veya üzerinde olması, bu bağlamda yağdan fakir AML tanısını destekleyen önemli bir kriter olarak kabul edilir.(Sasiwimonphan vd. 2016)

Onkositom

Onkositomalar, solid renal kitlelerin %3–7'sini oluşturur ve benign neoplazmlar olarak kabul edilir.(Rosenkrantz vd. 2010)Bu lezyonların en sık görüldüğü dönem 7. dekat ve erkeklerde daha yüksek prevalansa sahiptir.(Woo ve Cho 2015)

Onkositomalar, kromofob RHK'lerle aynı kökene sahiptir ve bu nedenle histolojik ve görüntüleme özellikleri açısından örtüşen benzerlikler gösterirler.(Rosenkrantz vd. 2010)

Olguların %54'üne kadarında, fibroz veya hyalinize bağ dokusundan ve sıkışmış kan damarlarından oluşan merkezi yıldız şeklinde bir skar görülebilir.(Galmiche vd. 2017)

Kromofob RHK'lerde olduğu gibi, onkositomalar da T2-ağırlıklı görüntülerde değişken sinyal intensitesi gösterebilir (genellikle hiperintens veya izointens) ve kortikomedüller fazda yoğun ya da orta derecede kontrast tutulum sergileyebilir(Şekil 5). Difüzyon kısıtlaması genellikle kromofob RHK'ye göre daha az belirgindir. Onkositomalarla ilişkilendirilen görüntüleme bulgularından biri de segmental kontrast tutulum inversiyonudur. Ancak bu bulgu tartışmalıdır; çünkü bazı RHK alt tipleri de bu bulguyu gösterebilir. MRG görüntülemesinde segmental kontrast tutulum inversiyonu için bildirilen duyarlılık %15, özgüllük ise %90'dır.(N vd. 2014)

Onkositomalar, değişken ve spesifik olmayan MRG bulguları sergiler; bu özellikler RHK'lerle örtüşebilir ve preoperatif olarak doğru tanı koymayı zorlaştırır. En sık, periferik yerleşimli, tamamen ya da büyük ölçüde iyi sınırlı ve belirgin kontrast tutulum gösteren lezyonlar olarak izlenirler.(Allen vd. 2014; Galmiche vd. 2017)

Onkositomalarda görülen merkezi skar görünümü, nekroz veya kistik değişikliklere bağlı olarak kromofob alt tip de dahil olmak üzere RHK'lerde de izlenebilir. Bu nedenle, merkezi skar varlığı tanıda ayırt edici bir özellik olarak kabul edilemez.(Galmiche vd. 2017)

Spesifik olmamakla birlikte, lezyon içindeki heterojen kontrastlanma paternindeki değişimlere bağlı olarak gelişen segmental kontrast tutulum inversiyonu, onkositomalarda görülebilir; ancak özellikle kromofob alt tip olmak üzere RHK'lerde de izlenebilir. Bu nedenle, bu bulgu tek başına ayırt edici değildir.(Galmiche vd. 2017; Rosenkrantz vd. 2010)


Kromofob RHK'lerde olduğu gibi, onkositomalar da genellikle perinefrik yağ dokusuna ya da renal vene invazyon göstermeden seyrederek.(Galmiche vd. 2017)

Sonuç





Solid böbrek kitlelerinin en önemli görüntüleme özelliklerinin tanınması, doğru tanı ve yönetimlerine yardımcı olabilir. Noninvaziv bir görüntüleme yöntemi olan multiparametrik MRG, yaygın RCC alt tipleri ve AML'ler dahil olmak üzere en sık görülen solid böbrek kitlelerinin ayırımında yardımcı olabilecek kritik bilgiler sağlar ve bu sayede bu lezyonların en uygun şekilde yönetimi ve takibi için yol gösterici olabilir.

Anahtar kelimeler: Renal hücreli karsinom(RHK), Anjiyomyolipom(AML), Onkositom, Bilgisayarlı tomografi(BT), Magnetik rezonans görüntüleme(MRG)


Şekil 1. Bertini kolon hipertrofisi. T2 ağırlıklı(a) Post-kontrast(b) MRG görüntüsü ve BT (c) görüntüsü





Şekil 2. Berrak Hücreli Tip RHK. Dış faz sekansta(b) İç faz sekansa(a) göre sinyal kaybı izleniyor. T2 ağırlıklı MRG sekansında(c) kistik alanlar içeren heterojen hiperintens lezyon izleniyor. Post-kontrast sekansta(d) solid alanlarda yoğun kontrastlanma izleniyor.




Şekil 3. 2 ayrı hastada papiller tip RHK. Sağ böbrekte posterior yerleşimli böbrek korteksşne göre hipovasküler lezyon(a). Sağ böbrekte kalın duvarlı böbrek korteksine göre hipovasküler lezyon (b).



Şekil 4. AML. BT(a) ve yağ baskılı T2 MRG(b) görüntüsünde makroskobik yağ(ok işareti) içeren lezyon izleniyor. İç faz ve dış faz MRG sekanslarında mikroskopik yağ ile uyumlu dış fazda sinyal kaybı izleniyor.



Şekil 5. 2 ayrı hastada onkositom. Sağ böbrekte kontrastlı BT görüntüsünde(a) orta düzeyde kontrast tutan solid lezyon(dolgulu ok). Sol böbrekte santral skar (ince ok işareti) içeren orta düzeyde kontrast tutan solid lezyon(b).



Kaynakça

- 2017 AUA Renal Mass and Localized Renal Cancer Guidelines: Imaging Implications | RadioGraphics. t.y. <https://pubs.rsna.org/doi/abs/10.1148/rg.2018180127>.
- Agochukwu, Nnenaya, Steffen Huber, Michael Spektor, Alexander Goehler, ve Gary M. Israel. 2017. "Differentiating Renal Neoplasms From Simple Cysts on Contrast-Enhanced CT on the Basis of Attenuation and Homogeneity". *American Journal of Roentgenology* 208(4):801-4. doi:10.2214/AJR.16.17119.
- Allen, Brian C., Philippe Tirman, M. Jennings Clingan, Julia Manny, Andrew J. Del Gaizo, ve John R. Leyendecker. 2014. "Characterizing Solid Renal Neoplasms with MRI in Adults". *Abdominal Imaging* 39(2):358-87. doi:10.1007/s00261-014-0074-4.
- Amin, Mahul B., Mitul B. Amin, Pheroze Tamboli, Javid Javidan, Hans Stricker, Mariza de-Peralta Venturina, Anita Deshpande, ve Mani Menon. 2002. "Prognostic Impact of Histologic Subtyping of Adult Renal Epithelial Neoplasms: An Experience of 405 Cases". *The American Journal of Surgical Pathology* 26(3):281-91. doi:10.1097/00000478-200203000-00001.
- Bissada, Nabil K., Hossam H. Yakout, Aga Babanouri, Tarek Elsalamony, Wahib Fahmy, Moustafa Gunham, Gerald W. Hull, ve Uzair B. Chaudhary. 2003. "Long-term experience with management of renal cell carcinoma involving the inferior vena cava". *Urology* 61(1):89-92. doi:10.1016/S0090-4295(02)02119-2.
- Cheville, John C., Christine M. Lohse, Horst Zincke, Amy L. Weaver, ve Michael L. Blute. 2003. "Comparisons of Outcome and Prognostic Features among Histologic Subtypes of Renal Cell Carcinoma". *The American Journal of Surgical Pathology* 27(5):612-24. doi:10.1097/00000478-200305000-00005.
- Combined gadolinium-enhanced and fat-saturation MR imaging of renal masses. | Radiology. t.y. <https://pubs.rsna.org/doi/abs/10.1148/radiology.178.3.1994422>.
- Comparison of 16-MDCT and MRI for Characterization of Kidney Lesions | AJR. t.y. <https://ajronline.org/doi/full/10.2214/AJR.04.1545>.
- Cornelis, F., E. Tricaud, A. S. Lasserre, F. Petitpierre, J. C. Bernhard, Y. Le Bras, M. Yacoub, M. Bouzgarrou, A. Ravaud, ve N. Grenier. 2015. "Multiparametric Magnetic Resonance Imaging for the Differentiation of Low and High Grade Clear Cell Renal Carcinoma". *European Radiology* 25(1):24-31. doi:10.1007/s00330-014-3380-x.
- Davenport, Matthew S., Amy M. Neville, James H. Ellis, Richard H. Cohan, Humaira S. Chaudhry, ve Richard A. Leder. 2011. "Diagnosis of Renal Angiomyolipoma with Hounsfield Unit Thresholds: Effect of Size of Region of Interest and Nephrographic Phase Imaging". *Radiology* 260(1):158-65. doi:10.1148/radiol.11102476.
- Diaz de Leon, Alberto, Matthew S. Davenport, Stuart G. Silverman, Nicola Schieda, Jeffrey A. Cadeddu, ve Ivan Pedrosa. 2019. "Role of Virtual Biopsy in the Management of Renal Masses". *AJR. American Journal of Roentgenology* 212(6):1234-43. doi:10.2214/AJR.19.21172.
- Differentiation of Solid Renal Tumors with Multiparametric MR Imaging | RadioGraphics. t.y. <https://pubs.rsna.org/doi/10.1148/rg.2017170039>.
- Dilauro, Marc, Matthew Quon, Matthew D. F. McInnes, Maryam Vakili, Andrew Chung, Trevor A. Flood, ve Nicola Schieda. 2016. "Comparison of Contrast-Enhanced Multiphase Renal Protocol CT Versus MRI for Diagnosis of Papillary Renal Cell Carcinoma". *American Journal of Roentgenology* 206(2):319-25. doi:10.2214/AJR.15.14932.

Farrell, Crystal, Sabrina L. Noyes, Mouafak Tourojman, ve Brian R. Lane. 2015. "Renal Angiomyolipoma: Preoperative Identification of Atypical Fat-Poor AML". *Current Urology Reports* 16(3):12. doi:10.1007/s11934-015-0484-z.

FRANK, IGOR, MICHAEL L. BLUTE, JOHN C. CHEVILLE, CHRISTINE M. LOHSE, AMY L. WEAVER, ve HORST ZINCKE. 2003. "Solid Renal Tumors: An Analysis of Pathological Features Related to Tumor Size". *The Journal of Urology*. doi:10.1097/01.ju.0000095475.12515.5e.

Galmiche, Chloe, Jean-Christophe Bernhard, Mokrane Yacoub, Alain Ravaud, Nicolas Grenier, ve François Cornelis. 2017. "Is Multiparametric MRI Useful for Differentiating Oncocytomas From Chromophobe Renal Cell Carcinomas?" *AJR. American Journal of Roentgenology* 208(2):343-50. doi:10.2214/AJR.16.16832.

Goiney, RC, L. Goldenberg, PL Cooperberg, JW Charboneau, AT Rosenfield, LD Russin, S. McCarthy, RK Zeman, PB Gordon, ve BA Rowley. 1984. "Renal oncocytoma: sonographic analysis of 14 cases". *American Journal of Roentgenology* 143(5):1001-4. doi:10.2214/ajr.143.5.1001.

Gurel, Safiye, Vamsi Narra, Khaled M. Elsayes, Cary Lynn Siegel, Zongming Eric Chen, ve Jeffrey J. Brown. 2013. "Subtypes of Renal Cell Carcinoma: MRI and Pathological Features". *Diagnostic and Interventional Radiology*. doi:10.5152/dir.2013.147.

Hakim, Shaheed W., Nicola Schieda, Taryn Hodgdon, Matthew D. F. McInnes, Marc Dilauro, ve Trevor A. Flood. 2016. "Angiomyolipoma (AML) without Visible Fat: Ultrasound, CT and MR Imaging Features with Pathological Correlation". *European Radiology* 26(2):592-600. doi:10.1007/s00330-015-3851-8.

Heilbrun, Marta E., Erick M. Remer, David D. Casalino, Michael D. Beland, Jay T. Bishoff, M. Donald Blaufox, Courtney A. Coursey, Stanley Goldfarb, Howard J. Harvin, Paul Nikolaidis, Glenn M. Preminger, Steven S. Raman, Anik Sahni, Raghunandan Vikram, ve Robert M. Weinfeld. 2015a. "ACR Appropriateness Criteria Indeterminate Renal Mass". *Journal of the American College of Radiology* 12(4):333-41. doi:10.1016/j.jacr.2014.12.012.

Heilbrun, Marta E., Erick M. Remer, David D. Casalino, Michael D. Beland, Jay T. Bishoff, M. Donald Blaufox, Courtney A. Coursey, Stanley Goldfarb, Howard J. Harvin, Paul Nikolaidis, Glenn M. Preminger, Steven S. Raman, Anik Sahni, Raghunandan Vikram, ve Robert M. Weinfeld. 2015b. "ACR Appropriateness Criteria Indeterminate Renal Mass". *Journal of the American College of Radiology* 12(4):333-41. doi:10.1016/j.jacr.2014.12.012.

Hélénon, O., Y. Chrétien, F. Paraf, P. Melki, A. Denys, ve J. F. Moreau. 1993. "Renal Cell Carcinoma Containing Fat: Demonstration with CT". *Radiology* 188(2):429-30. doi:10.1148/radiology.188.2.8327691.

Hindman, Nicole, Long Ngo, Elizabeth M. Genega, Jonathan Melamed, Jesse Wei, Julia M. Braza, Neil M. Rofsky, ve Ivan Pedrosa. 2012. "Angiomyolipoma with Minimal Fat: Can It Be Differentiated from Clear Cell Renal Cell Carcinoma by Using Standard MR Techniques?" *Radiology* 265(2):468-77. doi:10.1148/radiol.12112087.

Hodgdon, Taryn, Matthew D. F. McInnes, Nicola Schieda, Trevor A. Flood, Leslie Lamb, ve Rebecca E. Thornhill. 2015. "Can Quantitative CT Texture Analysis be Used to Differentiate Fat-poor Renal Angiomyolipoma from Renal Cell Carcinoma on Unenhanced CT Images?" *Radiology* 276(3):787-96. doi:10.1148/radiol.2015142215.

Hoffmann, Nathan E., Michael D. Gillett, John C. Cheville, Christine M. Lohse, Bradley C. Leibovich, ve Michael L. Blute. 2008. "Differences in Organ System of Distant Metastasis by Renal Cell Carcinoma Subtype". *The Journal of Urology*. doi:10.1016/j.juro.2007.09.036.

Hötker, Andreas M., Yousef Mazaheri, Andreas Wibmer, Christoph A. Karlo, Junting Zheng, Chaya S. Moskowitz, Satish K. Tickoo, Paul Russo, Hedvig Hricak, ve Oguz Akin. 2017. "Differentiation of Clear

Cell Renal Cell Carcinoma From Other Renal Cortical Tumors by Use of a Quantitative Multiparametric MRI Approach". *American Journal of Roentgenology* 208(3):W85-91. doi:10.2214/AJR.16.16652.

Israel, Gary M., ve Morton A. Bosniak. 2005. "How I Do It: Evaluating Renal Masses". *Radiology* 236(2):441-50. doi:10.1148/radiol.2362040218.

Israel, Gary M., ve Morton A. Bosniak. 2008. "Pitfalls in Renal Mass Evaluation and How to Avoid Them". *Radiographics: A Review Publication of the Radiological Society of North America, Inc* 28(5):1325-38. doi:10.1148/rg.285075744.

Israel, Gary M., Morton A. Bosniak, Chrystia M. Slywotzky, ve Robert J. Rosen. 2002. "CT Differentiation of Large Exophytic Renal Angiomyolipomas and Perirenal Liposarcomas". *AJR. American Journal of Roentgenology* 179(3):769-73. doi:10.2214/ajr.179.3.1790769.

Israel, Gary M., Nicole Hindman, Elizabeth Hecht, ve Glenn Krinsky. 2005. "The Use of Opposed-Phase Chemical Shift MRI in the Diagnosis of Renal Angiomyolipomas". *AJR. American Journal of Roentgenology* 184(6):1868-72. doi:10.2214/ajr.184.6.01841868.

Jeong, Chae Jin, Byung Kwan Park, Jung Jae Park, ve Chan Kyo Kim. 2016. "Unenhanced CT and MRI Parameters That Can Be Used to Reliably Predict Fat-Invisible Angiomyolipoma". *AJR. American Journal of Roentgenology* 206(2):340-47. doi:10.2214/AJR.15.15086.

Jinzaki, Masahiro, Stuart G. Silverman, Hirotaka Akita, Yoji Nagashima, Shuji Mikami, ve Mototsugu Oya. 2014. "Renal Angiomyolipoma: A Radiological Classification and Update on Recent Developments in Diagnosis and Management". *Abdominal Imaging* 39(3):588-604. doi:10.1007/s00261-014-0083-3.

Jonisch, Ari I., Ami N. Rubinowitz, Pradeep G. Mutalik, ve Gary M. Israel. 2007. "Can High-Attenuation Renal Cysts Be Differentiated from Renal Cell Carcinoma at Unenhanced CT?" *Radiology* 243(2):445-50. doi:10.1148/radiol.2432060559.

Journal of Computer Assisted Tomography. t.y.
https://journals.lww.com/jcat/abstract/1997/05000/helical_and_electron_beam_ct_scanning_in_the.24.aspx.

Karlo, Christoph A., Olivio F. Donati, Irene A. Burger, Junting Zheng, Chaya S. Moskowitz, Hedvig Hricak, ve Oguz Akin. 2013. "MR Imaging of Renal Cortical Tumours: Qualitative and Quantitative Chemical Shift Imaging Parameters". *European Radiology* 23(6):1738-44. doi:10.1007/s00330-012-2758-x.

Kay, Fernando U., ve Ivan Pedrosa. 2018. "Imaging of Solid Renal Masses". *The Urologic Clinics of North America* 45(3):311-30. doi:10.1016/j.ucl.2018.03.013.

Kidney Cancer in: Journal of the National Comprehensive Cancer Network Volume 9 Issue 9 (2011). t.y. <https://jnccn.org/view/journals/jnccn/9/9/article-p960.xml>.

Kim, Choo-Won, Krishna P. Shanbhogue, Jessica Schreiber-Zinaman, Fang-Ming Deng, ve Andrew B. Rosenkrantz. 2017. "Visual Assessment of the Intensity and Pattern of T1 Hyperintensity on MRI to Differentiate Hemorrhagic Renal Cysts From Renal Cell Carcinoma". *American Journal of Roentgenology* 208(2):337-42. doi:10.2214/AJR.16.16710.

Klatte, Tobias, Ken-ryu Han, Jonathan W. Said, Malte Böhm, Ernst Peter Allhoff, Fairouz F. Kabbinaar, Arie S. Belldegrun, ve Allan J. Pantuck. 2008. "Pathobiology and prognosis of chromophobe renal cell carcinoma". *Urologic Oncology: Seminars and Original Investigations* 26(6):604-9. doi:10.1016/j.urolonc.2007.07.015.

- Krishna, Satheesh, Ashley Leckie, Ania Kielar, Robert Hartman, ve Ashish Khandelwal. 2020. "Imaging of Renal Cancer". *Seminars in Ultrasound, CT and MRI* 41(2):152-69. doi:10.1053/j.sult.2019.12.004.
- Leroy, Xavier, Laurent Zini, Emmanuelle Leteurtre, Farid Zerimech, Nicole Porchet, Jean-Pierre Aubert, Bernard Gosselin, ve Marie-Christine Copin. 2002. "Morphologic Subtyping of Papillary Renal Cell Carcinoma: Correlation with Prognosis and Differential Expression of MUC1 between the Two Subtypes". *Modern Pathology: An Official Journal of the United States and Canadian Academy of Pathology, Inc* 15(11):1126-30. doi:10.1097/01.MP.0000036346.88874.25.
- Muglia, Valdair F., ve Adilson Prando. 2015. "Renal Cell Carcinoma: Histological Classification and Correlation with Imaging Findings". *Radiologia Brasileira* 48:166-74. doi:https://doi.org/10.1590/0100-3984.2013.1927.
- N, Schieda, Al-Subhi M, Flood Ta, El-Khodary M, ve McInnes Md. 2014. "Diagnostic Accuracy of Segmental Enhancement Inversion for the Diagnosis of Renal Oncocytoma Using Biphasic Computed Tomography (CT) and Multiphase Contrast-Enhanced Magnetic Resonance Imaging (MRI)". *European Radiology* 24(11). doi:10.1007/s00330-014-3310-y.
- Ng, Chaan S., Christopher G. Wood, Paul M. Silverman, Nizar M. Tannir, Pheroze Tamboli, ve Carl M. Sandler. 2008. "Renal Cell Carcinoma: Diagnosis, Staging, and Surveillance". *American Journal of Roentgenology* 191(4):1220-32. doi:10.2214/AJR.07.3568.
- O'Connor, Stacy D., Perry J. Pickhardt, David H. Kim, M. Raquel Oliva, ve Stuart G. Silverman. 2011. "Incidental Finding of Renal Masses at Unenhanced CT: Prevalence and Analysis of Features for Guiding Management". *American Journal of Roentgenology* 197(1):139-45. doi:10.2214/AJR.10.5920.
- Oliva, M. Raquel, Jonathan N. Glickman, Kelly H. Zou, Sze Y. Teo, Koenraad J. Mortelé, Manoel S. Rocha, ve Stuart G. Silverman. 2009. "Renal Cell Carcinoma: T1 and T2 Signal Intensity Characteristics of Papillary and Clear Cell Types Correlated with Pathology". *AJR. American Journal of Roentgenology* 192(6):1524-30. doi:10.2214/AJR.08.1727.
- Parada Villavicencio, Carolina, Robert J. Mc Carthy, ve Frank H. Miller. 2017. "Can Diffusion-Weighted Magnetic Resonance Imaging of Clear Cell Renal Carcinoma Predict Low from High Nuclear Grade Tumors". *Abdominal Radiology* 42(4):1241-49. doi:10.1007/s00261-016-0981-7.
- Park, Byung Kwan. 2017. "Renal Angiomyolipoma: Radiologic Classification and Imaging Features According to the Amount of Fat". *AJR. American Journal of Roentgenology* 209(4):826-35. doi:10.2214/AJR.17.17973.
- Pedrosa, Ivan, ve Jeffrey A. Cadeddu. 2022. "How We Do It: Managing the Indeterminate Renal Mass with the MRI Clear Cell Likelihood Score". *Radiology* 302(2):256-69. doi:10.1148/radiol.210034.
- Polascik, Thomas J., David G. Bostwick, ve Paul Cairns. 2002. "Molecular Genetics and Histopathologic Features of Adult Distal Nephron Tumors". *Urology* 60(6):941-46. doi:10.1016/S0090-4295(02)01825-3.
- Pooler, B. Dustin, Perry J. Pickhardt, Stacy D. O'Connor, Richard J. Bruce, Sutchin R. Patel, ve Stephen Y. Nakada. 2012. "Renal Cell Carcinoma: Attenuation Values on Unenhanced CT". *American Journal of Roentgenology* 198(5):1115-20. doi:10.2214/AJR.11.7587.
- Prasad, Srinivasa R., Peter A. Humphrey, Jay R. Catena, Vamsi R. Narra, John R. Srigley, Arthur D. Cortez, Neal C. Dalrymple, ve Kedar N. Chintapalli. 2006. "Common and Uncommon Histologic Subtypes of Renal Cell Carcinoma: Imaging Spectrum with Pathologic Correlation". *RadioGraphics* 26(6):1795-1806. doi:10.1148/rg.266065010.

Ramamurthy, N. K., B. Moosavi, M. D. F. McInnes, T. A. Flood, ve N. Schieda. 2015. "Multiparametric MRI of solid renal masses: pearls and pitfalls". *Clinical Radiology* 70(3):304-16. doi:10.1016/j.crad.2014.10.006.

Renal angiomyolipoma: a radiological classification and update on recent developments in diagnosis and management | Abdominal Radiology. t.y. <https://link.springer.com/article/10.1007/s00261-014-0083-3>.

Renal Mass Imaging with MRI Clear Cell Likelihood Score: A User's Guide | RadioGraphics. t.y. <https://pubs.rsna.org/doi/full/10.1148/rg.220209>.

Rosenkrantz, Andrew B., Nicole Hindman, Erin F. Fitzgerald, Benjamin E. Niver, Jonathan Melamed, ve James S. Babb. 2010. "MRI Features of Renal Oncocytoma and Chromophobe Renal Cell Carcinoma". *AJR. American Journal of Roentgenology* 195(6):W421-427. doi:10.2214/AJR.10.4718.

Rosenkrantz, Andrew B., Aarti Sekhar, Elizabeth M. Genega, Jonathan Melamed, James S. Babb, Amish D. Patel, Andy Lo, Robert M. Najarian, Muneeb Ahmed, ve Ivan Pedrosa. 2013. "Prognostic Implications of the Magnetic Resonance Imaging Appearance in Papillary Renal Cell Carcinoma". *European Radiology* 23(2):579-87. doi:10.1007/s00330-012-2631-y.

Roy, Catherine, Sofiane El Ghali, Xavier Buy, Veronique Lindner, Herve Lang, Christian Saussine, ve Didier Jacqmin. 2005. "Significance of the Pseudocapsule on MRI of Renal Neoplasms and Its Potential Application for Local Staging: A Retrospective Study". *American Journal of Roentgenology* 184(1):113-20. doi:10.2214/ajr.184.1.01840113.

Sasiwimonphan, Kewalee, Naoki Takahashi, Bradley C. Leibovich, Rickey E. Carter, Thomas D. Atwell, ve Akira Kawashima. 2016. "Small (<4 Cm) Renal Mass: Differentiation of Angiomyolipoma without Visible Fat from Renal Cell Carcinoma Utilizing MR Imaging". *Radiology* 280(2):653. doi:10.1148/radiol.2016164024.

Schieda, N., A. Z. Kielar, O. Al Dandan, M. D. F. McInnes, ve T. A. Flood. 2015. "Ten uncommon and unusual variants of renal angiomyolipoma (AML): radiologic-pathologic correlation". *Clinical Radiology* 70(2):206-20. doi:10.1016/j.crad.2014.10.001.

Shetty, C. M., B. N. Lakhkar, B. V. Devi, ve B. S. Lakshmi. 2004. "Dual - Phase Helical CT of Kidney : Comparison of Corticomedullary and Nephrographic Phases in Detection and Characterization of Renal Masses". 14(3):285-90.

Sidhar, Kunal, John P. McGahan, Heather M. Early, Michael Corwin, Ghanesh Fananapazir, ve Eugenio O. Gerscovich. 2016. "Renal Cell Carcinomas". *Journal of Ultrasound in Medicine* 35(2):311-20. doi:10.7863/ultra.15.03051.

Silverman, Stuart G., Gary M. Israel, Brian R. Herts, ve Jerome P. Richie. 2008. "Management of the Incidental Renal Mass". *Radiology* 249(1):16-31. doi:10.1148/radiol.2491070783.

Small (<1 cm) incidental echogenic renal cortical nodules: chemical shift MRI outperforms CT for confirmatory diagnosis of angiomyolipoma (AML) | Insights into Imaging. t.y. <https://link.springer.com/article/10.1007/s13244-014-0323-7>.

Solid Renal Masses: What the Numbers Tell Us | AJR. t.y. <https://ajronline.org/doi/full/10.2214/AJR.14.12502>.

Song, Sohee, Byung Kwan Park, ve Jung Jae Park. 2016. "New Radiologic Classification of Renal Angiomyolipomas". *European Journal of Radiology* 85(10):1835-42. doi:10.1016/j.ejrad.2016.08.012.

Steiner, M. S., S. M. Goldman, E. K. Fishman, ve F. F. Marshall. 1993. "The Natural History of Renal Angiomyolipoma". *The Journal of Urology* 150(6):1782-86. doi:10.1016/s0022-5347(17)35895-0.

- Strotzer, M., K. B. Lehner, ve K. Becker. 1993. "Detection of Fat in a Renal Cell Carcinoma Mimicking Angiomyolipoma". *Radiology* 188(2):427-28. doi:10.1148/radiology.188.2.8327690.
- Tanaka, Hajime, Soichiro Yoshida, Yasuhisa Fujii, Chikako Ishii, Hiroshi Tanaka, Fumitaka Koga, Kazutaka Saito, Hitoshi Masuda, Satoru Kawakami, ve Kazunori Kihara. 2011. "Diffusion-Weighted Magnetic Resonance Imaging in the Differentiation of Angiomyolipoma with Minimal Fat from Clear Cell Renal Cell Carcinoma". *International Journal of Urology: Official Journal of the Japanese Urological Association* 18(10):727-30. doi:10.1111/j.1442-2042.2011.02824.x.
- Tappouni, Rafel, Jennifer Kissane, Nabeel Sarwani, ve Erik B. Lehman. 2012. "Pseudoenhancement of Renal Cysts: Influence of Lesion Size, Lesion Location, Slice Thickness, and Number of MDCT Detectors". *American Journal of Roentgenology* 198(1):133-37. doi:10.2214/AJR.10.6057.
- Volpe, Alessandro, Giacomo Novara, Alessandro Antonelli, Roberto Bertini, Michele Billia, Giorgio Carmignani, Sergio Cosciani Cunico, Nicola Longo, Guido Martignoni, Andrea Minervini, Vincenzo Mirone, Alchiede Simonato, Carlo Terrone, Filiberto Zattoni, Vincenzo Ficarra, Surveillance and Treatment Update on Renal Neoplasms (SATURN) Project, ve Leading Urological No-Profit Foundation for Advanced Research (LUNA) Foundation. 2012. "Chromophobe Renal Cell Carcinoma (RCC): Oncological Outcomes and Prognostic Factors in a Large Multicentre Series". *BJU International* 110(1):76-83. doi:10.1111/j.1464-410X.2011.10690.x.
- Wang, Haiyi, Liuquan Cheng, Xu Zhang, Dianjun Wang, Aitao Guo, Yuangui Gao, ve Huiyi Ye. 2010. "Renal Cell Carcinoma: Diffusion-Weighted MR Imaging for Subtype Differentiation at 3.0 T". *Radiology* 257(1):135-43. doi:10.1148/radiol.10092396.
- Wang, Zhen Jane, Matthew S. Davenport, Stuart G. Silverman, Hersh Chandarana, Ankur Doshi, Gary M. Israel, John R. Leyendecker, Ivan Pedrosa, Steve Raman, Erick M. Remer, Atul B. Shinagare, Andrew D. Smith, ve Raghu Vikram. t.y. "CT Renal Mass Protocols v1.0".
- Wilson, Mitchell P., Deelan Patel, Prayash Katlariwala, ve Gavin Low. 2021. "A Review of Clinical and MR Imaging Features of Renal Lipid-Poor Angiomyolipomas". *Abdominal Radiology (New York)* 46(5):2072-78. doi:10.1007/s00261-020-02835-6.
- Woo, Sungmin, ve Jeong Yeon Cho. 2015. "Imaging Findings of Common Benign Renal Tumors in the Era of Small Renal Masses: Differential Diagnosis from Small Renal Cell Carcinoma: Current Status and Future Perspectives". *Korean Journal of Radiology* 16(1):99-113. doi:10.3348/kjr.2015.16.1.99.
- Woo, Sungmin, Jeong Yeon Cho, Seung Hyup Kim, Sang Youn Kim, Hak Jong Lee, Sung Il Hwang, Min Hoan Moon, ve Chang Kyu Sung. 2013. "Segmental Enhancement Inversion of Small Renal Oncocytoma: Differences in Prevalence According to Tumor Size". *AJR. American Journal of Roentgenology* 200(5):1054-59. doi:10.2214/AJR.12.9300.
- Yamakado, Koichiro, Naoshi Tanaka, Toshio Nakagawa, Shigeki Kobayashi, Makoto Yanagawa, ve Kan Takeda. 2002. "Renal Angiomyolipoma: Relationships between Tumor Size, Aneurysm Formation, and Rupture". *Radiology* 225(1):78-82. doi:10.1148/radiol.2251011477.
- Yoshimitsu, Kengo, Daisuke Kakihara, Hiroyuki Irie, Tsuyoshi Tajima, Akihiro Nishie, Yoshiki Asayama, Masakazu Hirakawa, Tomohiro Nakayama, Seiji Naito, ve Hiroshi Honda. 2006. "Papillary Renal Carcinoma: Diagnostic Approach by Chemical Shift Gradient-Echo and Echo-Planar MR Imaging". *Journal of Magnetic Resonance Imaging: JMRI* 23(3):339-44. doi:10.1002/jmri.20509.
- Yuh, B. I., ve R. H. Cohan. 1999. "Different phases of renal enhancement: role in detecting and characterizing renal masses during helical CT." *American Journal of Roentgenology* 173(3):747-55. doi:10.2214/ajr.173.3.10470916.

BÖLÜM 3

ADRENAL LEZYONLARA YAKLAŞIM

SADULLAH ŞİMŞEK¹

GİRİŞ

Adrenal bezler, her iki böbreğin anterosüperior ve hafif medialinde retroperitoneal yerleşim gösteren üçgen şeklinde endokrin bezlerdir. Her bir adrenal bezin bir gövdesi ve iki bacağı vardır. Hormon üretiminde önemli bir rol oynar. Her bir adrenal bez korteks ve medulla olmak üzere iki ana bölümden oluşur. Adrenal korteks mineralokortikoid, glukokortikoid, androjen hormonlarının üretildiği katmandır. Adrenal medulla adrenalın ve nöradrenalin olarak bilinen hormonlarının üretildiği katmandır.

Son yıllarda kesitsel görüntülemenin kullanımı artmıştır. Bu nedenle adrenal lezyonların tespiti artmıştır. Genellikle bu lezyonlar başka bir nedenle yapılan görüntülemelerde insidental olarak tespit edilir. İnsidental adrenal nodül prevalansı, geniş otopsi serilerinde %6, bilgisayarlı tomografi (BT) tetkiki yapılan hastalarda yaklaşık %4-5 olup yaş ile birlikte oran artmaktadır (1). En sık tespit edilen insidental adrenal nodül benign adenomdur. Büyük bir oranda

¹ Uzman Doktor, S.B.Ü. Gazi Yaşargil Eğitim Araştırma Hastanesi, Radyoloji, Diyarbakır, sadullahsimsek@gmail.com
ORCID: 0000-0002-8322-7475

fonksiyon göstermezler. Ayrıca insidental olarak adrenokortikal tümörler, feokromasitoma, metastaz gibi lezyonlarda tespit edilmektedir. Bu lezyonları tespit ederken hastaların klinik öykü, hormon, laboratuvar bulguları, fizik muayene göz önünde bulundurulması gerekir. Bu bulgular eşliğinde uygun görüntüleme yöntemi ve protokolü seçilmelidir. Herhangi bir anormallik yoksa radyolojik değerlendirme önem kazanmaktadır (2,3).

Bu yazıda; adrenal bez tümörlerinin görüntülenmesinde kullanılan yöntem ve protokoller anlatılacak, en sık görülen benign ve malign adrenal bez tümörlerinin radyolojik bulguları değerlendirilecektir.

GÖRÜNTÜLEME YÖNTEMLERİ

Adrenal bezini değerlendirmek için genellikle ultrasonografi(US), bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi invaziv olmayan yöntemler kullanılır. Bazı durumlarda sintigrafi veya pozitron emisyon tomografisi-bilgisayarlı tomografi (PET-BT) yapılabilir.

US radyasyon tehlikesi olmadığı için çocuklarda yapılır. Yenidoğanlarda adrenal hemoraji tanı-takibi için kullanılmaktadır. Erişkinlerde küçük lezyonların tespiti zor olduğundan sıklıkla büyük adrenal lezyon tanı ve takibinde kullanılmaktadır.

BT, adrenal lezyonları değerlendirmek için en sık kullanılan görüntüleme yöntemidir. Kontrastsız BT, karakteristik özelliklere sahip olan kistleri, miyelolipomları ve adrenal hemorajiyi teşhis edebilir. Ayrıca HU(Hounsfield Unit) ölçümü yaparak yağdan zengin adenomların tanısını koyabilir. Kontrast madde kullanarak trifazik dinamik inceleme yapılabilir ve kontrastlanma ve yıkanma oranı ile spesifik tanı konulabilir. Ancak, atipik bulgulara veya küçük boyuta sahip bir adrenal bez lezyonu için BT kullanarak spesifik bir tanı elde etmek zordur(4).

MRG, özellikle adrenal kitlelerin karakterizasyonunda BT'ye alternatif olarak kullanılır. Yumuşak doku kontrastı ile üstünlük sağlar. Kimyasal şift görüntüleme tekniği ile yağdan zengin adenomların tanımlanmasında önemli rol oynar(5).

Metaiyodobenzilguanidin (MIBG) sintigrafisi, feokromositoma tanısında, Octreotide sintigrafisi insülinoma gibi hormonal aktivite gösteren lezyonların tespitinde yüksek doğruluğa sahiptir.

PET-BT, özellikle adrenal lezyonların malignitesini değerlendirmek için kullanılan bir başka görüntüleme yöntemidir. 18F-FDG PET (florodeoksiglukoz) kullanılarak, metabolik aktiviteyi değerlendirmek mümkündür .

ADRENAL LEZYONLAR

ADENOM

Adrenal adenomlar en sık görülen adrenal neoplazmdır ve otopsi serilerinde vakaların %1,4-8,9'unda bulunur(6). Adenomların çoğu non-fonksiyoneldir. Yaklaşık %6'sı fonksiyonel özellik göstermektedir(6). Adenomlar tipik olarak, bol lipid içeriği olan 1–3 cm çapında, iyi sınırlı kapsüllü lezyonlardır. Adenomlarda büyük boyut, kalsifikasyonlar, hemoraji, kistik görünüm nadir görülen özelliklerdir(7). BT'de adenomlar genellikle homojen, iyi sınırlı lezyonlardır. Kontrastsız BT'deki karakteristik düşük atenüasyon(<10 HU) göstermektedir(8)(Resim 1). 10 HU ve daha düşük dansite değerleri %71 duyarlılık ve %98 özgüllük ile yağdan zengin adenomlar için tanısaldır(8) .Düşük atenüasyon intrasitoplazmik yağ içeriğine bağlı olarak gelişir. Olguların % 70'i lipid açısından zengin adenomlar oluşturur. Lipid açısından fakir adenomlar (%30), kontrastsız BT'de daha yüksek atenüasyon değerlerine sahiptir. Bu lezyonlar belirsiz olarak kabul edilir. Dinamik inceleme gerekir. Hem lipid açısından zengin hem de lipid açısından fakir adenomlar patognomonik hızlı kontrastlanma ve hızlı

washout(yıkanma) gösterir. Yüksek tanısal doğruluğu göz önüne alındığında, dinamik adrenal BT tercih edilen görüntüleme testi olarak düşünülebilir. Dinamik adrenal BT(üç fazlı) kontrastsız, portal venöz faz(60-90 dakika) ve geç faz(15. dakika) olmak üzere uygulanan protokoldür. Her fazda ölçülen HU değerleri ile mutlak ve rölatif yıkanma oranları hesaplanır.

Mutlak yıkanma oranı: Portal Venöz Faz(HU)-Geç Venöz Faz(HU)/ Portal Venöz Faz(HU)-Kontrastsız(HU) x100

Rölatif Yıkanma Oranı: Portal Venöz Faz(HU)-Geç Venöz Faz(HU)/ Portal Venöz Faz(HU) x100

Adenomlar için %60'tan büyük mutlak yıkanma oranı veya %40'tan büyük rölatif yıkanma oranı, adenomun tanısı için %88 ila %96 arasında değişen duyarlılık ve %96 ila %100 arasında değişen özgüllük bildirmiştir(9). HU ölçümü yaparken lezyon santralinden, çevre mezenterik dokuları dahil etmemek gerekir. Ayrıca kalsifikasyon, kist, hemoraji varsa bu alana dahil edilmemelidir.

Kimyasal şift MRG, lipide duyarlı bir tekniktir. Solid adrenal lezyonların MRG değerlendirmesinin temelini oluşturur. MRG, belirli bir vokseldeki yağ ve sudaki protonların farklı presesyonel frekansları nedeniyle hücre içi lipidi belirler(10). Bu, faz içi görüntülerle karşılaştırıldığında faz dışı görüntülerde sinyal yoğunluğu kaybı olur. Bu sinyal değişikliği hem kalitatif-görsel olarak, hem de adrenal-splenik oran (ASO) ve adrenal sinyal intensite indeksi (ASİİ) hesaplanarak kantitatif olarak değerlendirilebilir.

$$ASO = \left[\frac{(Lezyon Sİ/Dalak Sİ) \text{ dış faz}}{(Lezyon Sİ/Dalak Sİ) \text{ iç faz}} \right] \times 100$$

$$ASİİ = \frac{(Lezyon Sİ iç faz) - (Lezyon Sİ dış faz)}{(Lezyon Sİ iç faz)} \times 100$$

Farklı çalışmalarda farklı değerler belirtilse de, genel kabul 1.5T sistemlerde ASO'nun <%71, ASİİ'nin >%16,5 olması durumunda yüksek doğrulukla yağdan zengin adenom tanısının konulabileceği yönündedir(11).

Adrenal lezyonları tanımlamak için görüntüleme yöntemi seçerken yağ içeriği önem kazanmaktadır. MRG 10-30 HU dansiteli hastalarda BT ye göre daha avantajlı olmakla beraber 30 HU üzeri hastalar için dinamik adrenal BT daha fazla avantaj sağlar. MRG 30 HU dansiteli lezyonlarda tanısal değeri BT ye göre belirgin azalmaktadır(4, 12).

PET-BT incelemelerinde adenomların yaklaşık %5'inde anlamlı FDG tutulumu gözlenebilmektedir(3). FDG tutulum derecesi adenomların fonksiyonel durumu ile ilişkili olabilir(3).

MİYELOLİPOM

Adrenal miyelolipom, makroskopik yağ ve hematopoetik doku içeren iyi huylu bir tümördür. Çoğu miyelolipom 5 cm'den küçüktür ve asemptomatiktir. Büyük boyutlu lezyonlarda bazen tümör içi kanama ve nekroz veya çevre yapılarda kitle etkisi nedeniyle yan ağrısına neden olurlar(13). Kontrastsız BT de kitle içerisinde makroskopik yağ bileşeni olması ve -30 HU dan düşük dansiteli olmasıyla tanı konulur. MRG'de makroskopik yağ ve T1 yağ baskılı görüntülerde baskılanması tanı koydurucudur(3). Kalsifikasyon, nekroz, hemoraji nadirdir.

GANGLİONÖROMA

Ganglionöroma, sempatik ganglionlardan kaynaklanan iyi huylu bir nörojenik tümördür. Paravertebral sempatik plexus

boyunca ve adrenal medulladan ortaya çıkabilir. Kendiliğinden oluşabileceği gibi nöroblastom ile ganglionöroblastomun matürasyonu veya bunların kemoterapi ile tedavisinden sonra ortaya çıkabilir(14). Adrenal ganglionöromlar, kesitsel görüntülemelerde oval, kapsüllü, lobüle olan iyi tanımlanmış kitleler olarak görünür. Ganglionöromlar, kontrastsız BT'de düşük kontrastlanma gösteren kitlelerdir (< 40 HU) ve kontrastlı BT'de progressif kontrastlanma gösteren homojen veya heterojen kitlelerdir(14). Ganglionöroma, MRG'de karakteristik bir özellik olarak Schwann hücreleri ve kollajen liflerinin daha kalın iç içe geçmiş demetlerinden kaynaklanan girdaplı bir görünüm gösterebilir(15).

FEOKROMOSİTOMA

Feokromositoma, adrenal medulladaki kromafin hücrelerinden kaynaklanan katekolamin salgılayan nöroendokrin tümörlerdir. Feokromositomalar, tüm adrenal lezyonları %5'ini oluşturur(16). Feokromositomalarla ilişkili kalıtsal sendromlar arasında multiple endokrin neoplazi tip 2, Von Hippel-Lindau hastalığı, nörofibromatozis tip 1 ve süksinat dehidrogenaz mutasyonları bulunur(3). Tanı, serum ve idrar metanefrin düzeylerinin (katekolamin metabolitleri) yükselmesiyle desteklenir. Feokromositomalar, hem iyi huylu hem de kötü huylu neoplazmları taklit edebilen değişken görüntüleme özelliklerine sahiptir. BT'de tümörler genellikle yuvarlak veya oval kitlelerdir ve kontrastsız BT görüntülemelerde çevredeki yumuşak doku yapılar ile benzer dansite gösterirler. Kontrastlı BT tetkikinde hipervasküler karakterleri nedeniyle feokromositomalar, portal venöz fazda (>130 HU) yoğun kontrast tutulumu gösterir(17). Geç fazda yıkanma gösterdiği için MYO ve RYO adenom ile benzer olabilir. Adenom ve metastaz ile karıştırılabilir(9).

MRG, feokromositoma tanısında %98'lere ulaşan duyarlılığa sahiptir Feokromositomaların yaklaşık % 11 inde T2A serilerde

karakteristik “parlak ampül” bulgusu olarak adlandırılan hiperintens sinyal görünümü mevcuttur(18). Kistik alanlar içerebilir. İntrasitoplazmik yağ içermezler. Difüzyon ağırlıklı görüntüler tanıda etkinliği yoktur Karaciğer ve lenf nodu metastazları tanısında etkin rol oynar.

Feokromositomaların radyonüklid görüntülemesinde bir dizi ajan kullanılmıştır. MIBG taraması, %100'e yaklaşan bir özgüllük ve %79 ila %88 arasında değişen bir duyarlılıkla tümörleri lokalize etmek için tercih edilen görüntüleme tekniğidir(19). Feokromositomalar malign- benign ayrımı olmadan FDG PET'in artmış tutulumunu gösterir. 18F-florodopa, 18F-florodopamin veya 11C-hidroksiefedrin ile PET, MIBG taramasına alternatif olarak mevcuttur(3). Ga₆₈-DOTA peptidler kullanılarak yapılan PET/BT, somatostatin reseptörü eksprese eden feokromositoma ve paragangliomaların tanısında %90'dan fazla duyarlılık ve özgüllüğe sahip olup sintigrafiye üstünlük sağlamaktadır(20, 21)

ADRENAL KORTİKAL KARSİNOM

Adrenal korteksin en sık görülen primer malign neoplazmidir ve tüm adrenal lezyonların %5'inden azını oluşturur ve 1 milyon nüfusta 1-2 vaka prevalansı vardır(22). Yaklaşık % 60 ı fonksiyonel özellik göstermektedir. Tedavi edilmeyen olgular ölümcül seyir gösterebilir. Malignite öyküsü olmayan olgularda 4 cm'den büyük adrenal lezyonlarda adrenokortikal karsinom akılda tutulmalıdır. Lezyon boyutu 12 cm ye ulaşmakta olup düzensiz sınırlı ve heterojen iç yapıda olup kistik-nekrotik değişiklikler, kanama ve kalsifikasyon içerebilirler. Lokal invazyon, paraaortik lenfadenopati, uzak metastaz görülebilir(22).

Kontrastsız BT'de, adrenokortikal karsinomlar, heterojen yapıda, komşu yapılara bası oluşturan ve 10 HU'dan büyük atenüasyona sahip böbrek üstü kitleleridir. Kontrastlı BT'de, adrenokortikal karsinomlar, periferik heterojen kontrastlanma

gösterir ve adrenal adenomdan daha yavaş yıkanma gösterir (mutlak yıkama yüzdesi $< \%60$ ve rölatif yıkama yüzdesi $< \%40$)(23, 24)(Resim 2).

MRG'de heterojen iç yapıda, genellikle T1A serilerde karaciğer ile izointens, T2A serilerde hiperintens özellik gösterir. Kontrast madde sonrası güçlü ve heterojen kontrastlanma ve yavaş yıkanma gösterir. Hemoraji ve nekroz alanları içerebilir. FDG PET'te, adrenokortikal karsinomlar genellikle yüksek tutulum gösterir(25). Metastazların ve kemoterapi yanıtının değerlendirilmesinde ve BT'de tespit edilen rekürrens şüphesinin doğrulanmasında PET-BT kullanılmaktadır.

LENFOMA

Primer adrenal lenfoma son derece nadirdir. Ekstranodal lenfomaların $\%3$ 'ünü oluşturur(26). Bu lezyonların çoğu difüz büyük B-hücreli lenfomadır. Ekstraadrenal hastalığın eşlik etmediği bilateral iyi sınırlı büyük adrenal kitlenin tespit edilmesi durumunda primer adrenal lenfomadan şüphelenilmelidir. Sekonder adrenal lenfoma çok daha yaygındır. Postmortem muayenelerinin $\%25$ 'ine kadarında bildirilmiştir(27). İpsilateral böbrek, retroperiton tutulum ve splenomegali eşlik edebilir. Lenfadenopati sıklıkla görülür. Primer adrenal lenfomaların çoğu adrenal bezleri silen iyi sınırlı fokal veya multifokal büyük yumuşak doku kitleleri şeklinde izlenirken, sekonder adrenal lenfomalar normal bez morfolojisinin korunduğu difüz genişleme şeklinde ortaya çıkar(26, 28). BT'de primer adrenal lenfoma, homojen ve heterojen desenlerin yaklaşık olarak eşit dağılımını gösterir. Bu tümörlerin çoğu hipodens görünümündedir. Kontrast madde sonrası hafif-orta düzeyde kontrastlanmaya sahiptir. Tedavi öncesinde kalsifikasyon nadirdir. MRG'de, primer ve sekonder lenfomalar T1 ağırlıklı görüntülerde hipointens ile izointens ve T2 ağırlıklı görüntülerde hiperintensdir. Genellikle hafif ile orta düzeyde kontrast tutulumu görülür. Bu

kistlelerde yoğun sellülarite nedeniyle, difüzyon ağırlıklı görüntülerde kısıtlı difüzyon görülür. Adrenal lenfomalar da FDG PET'te yüksek tutulum göstermektedir.

NÖROBLASTOM

En yaygın ekstrakraniyal solid çocukluk çağı malignitesi olara kabul edilir. Paravertebral sempatik zincir boyunca herhangi bir yerde ortaya çıkabilmelerine rağmen, büyük çoğunluğu adrenal bezden kaynaklanır. Çocukluk çağı kanser ölümlerinin yaklaşık %15'ini oluştururlar.

Genellikle asemptomatiktir. Komşu organlara invazyon ve bası etkisi gösterdiğinde semptomatik hale gelebilir. Katekolamin üretimine sekonder hipertansiyon ve taşikardi gibi semptomlar görülebilir. Tanı anında olguların yarısından fazlasında karaciğer ve/veya kemik metastazı görülür.

BT görüntülemeye %80-90 oranında kalsifikasyon saptanır. Lezyon komşuluğundaki vasküler yapıları invaze etmeden çepeçevre sarma eğilimindedir. Bası etkisi gösterebilir. Aort posterior kesiminden orta hattı geçebilir. Aaortu vertebral kolondan ayıracak şekilde öne doğru itebilir(29).

MR özellikleri değişken olup genellikle T1A görüntülerde hipointens, T2A görüntülerde hiperintens heterojen kitleler şeklinde izlenir. Kalsifikasyonlara bağlı sinyalsiz alanlar görülür. Kanamaya bağlı T1A görüntülerde hiperintens, kistik alanlar T2A görüntülerde hiperintens izlenir.

Tanı ve evrelemede I₁₂₃-MIBG sintigrafisi ve FDG PET-BT; kemik metastazlarının gösterilmesinde Teknesyum ^{99m}-Metildifosfonat kullanılabilir(29).

METASTAZ

Adrenal metastaz, adrenal lezyonların küçük bir kısmını oluşturur. Malign hastalık öyküsü olan hastalarda adrenal bezlere metastaz yaygındır. Genellikle bilateralidir. Akciğer, meme, melanom, böbrek, kolon, pankreas, karaciğer ve mideden kaynaklanan malign tümörler genellikle adrenal bezlere metastaz yapar(2).


Standart görüntülemelerde metastazı adrenal adenom veya diğer adrenal nodülden ayırt etmek zor olmaktadır. FDG PET, malign hastalık öyküsü olan hastalarda adrenal metastazı tespit etmek için diğer görüntüleme yöntemlerinden daha yararlı olabilir, yüksek duyarlılık ve özgüllüğe sahiptir(Resim 3). Ancak, iyi huylu adrenal lezyonların %16'sı arka plana göre yanlış pozitif FDG tutulumu gösterebilir. Hemorajik veya nekrotik adrenal metastazlarda, küçük metastatik nodüllerde (< 1 cm) yanlış negatif bulgular görülebilir(30). Bu nedenle, altta yatan malignitesi olan hastalarda, PET-BT'de adrenal bezindeki FDG tutulumunun metastaz açısından dikkatli yorumlanması gerekir.

SONUÇ


Adrenal lezyonların radyolojik görüntüleri benzerdir. Bu lezyonları ayırt etmek için kimyasal shift MRG ve dinamik protokollü adrenal BT önem kazanmaktadır. Benign ve malign lezyon ayrımı önemli rol oynamaktadır. Bu lezyonları raporlarken hastaların klinisyenlerle beraber hareket etmek önem kazanmaktadır. Hastaların klinik öykü ve semptomları, biyokimyasal değerlerinin sorgulanması, eski tetkiklerle karşılaştırma yapılarak lezyon boyutunun ve morfolojik özelliklerinin zaman içerisinde değişimini göz önünde bulundurmak gerekir.

Anahtar kelimeler: Adrenal, Kitle, Bilgisayarlı Tomografi(BT), Manyetik Rezonans Görüntüleme(MRG).


Resim 1: Sol adrenal bezde 10 HU dan düşük dansiteli adenom lehine değerlendirilen kitlesel lezyon mevcuttur.



Resim 2: Sağ adrenal bezde kontrastlı BT görüntülemeye heterojen kontrst tutulumu gösteren kitlesel lezyon mevcuttur. Operasyon sonrası adrenokortikal karsinom olarak histopatolojik olarak doğrulandı.



Resim 3: Sol adrenal bezde kitlesi saptanan ve akciğer kanseri öyküsü bulunan hastanın PET/BT görüntülemesinde Suvmax değeri arttığı görülmektedir. Lezyon metastaz olarak değerlendirildi.



Kaynakça

Schieda N, Siegelman ES. Update on CT and MRI of adrenal nodules. *AJR Am J Roentgenol*. 2017; 208: 1206-17.

Young WF Jr. Clinical practice. The incidentally discovered adrenal mass. *N Engl J Med*. 2007; 356: 601-10.

Shin YR, Kim KA. Imaging features of various adrenal neoplastic lesions on radiologic and nuclear medicine imaging. *AJR Am J Roentgenol*. 2015; 205: 554-63.

Blake MA, Cronin CG, Boland GW. Adrenal imaging. *Am J Roentgenol*. 2010; 194: 1450-60.

Stephanie Ryan, Michelle McNicholas, Stephen J. Eustace. *Anatomy for Diagnostic Imaging*. (2011) ISBN: 9780702029714.

Boland GW, Blake MA, Hahn PF, Mayo-Smith WW. Incidental adrenal lesions: principles, techniques, and algorithms for imaging characterization. *Radiology* 2008; 249:756–75.

Johnson PT, Horton KM, Fishman EK. Adrenal mass imaging with multidetector CT: pathologic conditions, pearls, and pitfalls. *RadioGraphics* 2009; 29:1333–51.

Boland GW, Lee MJ, Gazelle GS, Halpern EF, McNicholas MM, Mueller PR. Characterization of adrenal masses using unenhanced CT: an analysis of the CT literature. *AJR* 1998; 171:201–4.

Caoili EM, Korobkin M, Francis IR, et al. Adrenal masses: characterization with combined unenhanced and delayed enhanced CT. *Radiology* 2002; 222:629–33.

Israel GM, Korobkin M, Wang C, Hecht EN, Krinsky GA. Comparison of unenhanced CT and chemical shift MRI in evaluating lipid-rich adrenal adenomas. *AJR* 2004; 183:215–9.

Yüksek, Hasan Hüsnü, and Feramuz Demir Apaydın. "Adrenal Bez Tümörlerinde Görüntüleme." *Turk Radiol Semin* 2024;12(2):315-46.

Sebro R, Aslam R, Muglia V. When is MRI unlikely to characterize an indeterminate adrenal nodule, based on density on an unenhanced CT. *Abdominal Radiology Course*. 2013.

Malayeri AA, Zaheer A, Fishman EK, Macura KJ. Adrenal masses: contemporary imaging characterization. *J Comput Assist Tomogr* 2013; 37:528–42.

Guo YK, Yang ZG, Li Y, Deng YP, Ma ES, Min PQ, et al. Uncommon adrenal masses: CT and MRI features with histopathologic correlation. *Eur J Radiol*. 2007; 62: 359-70.

Lattin GE Jr, Sturgill ED, Tujo CA, Marko J, Sanchez-Maldonado KW, Craig WD, et al. From the radiologic pathology archives: adrenal tumors and tumor-like conditions in the adult: radiologic-pathologic correlation. *Radiographics*. 2014; 34: 805-29.

Lenders JW, Eisenhofer G, Mannelli M, Pacak K. Pheochromocytoma. *Lancet* 2005; 366:665–75.

Chung R, Garratt J, Remer EM, Navin P, Blake MA, Taffel MT, et al. Adrenal neoplasms: lessons from adrenal multidisciplinary tumor boards. *Radiographics*. 2023; 43: e220191.

Jacques AE, Sahdev A, Sandrasagara M, et al. Adrenal pheochromocytoma: correlation of MRI appearances with histology and function. *Eur Radiol* 2008; 18:2885–92.

Shapiro B, Copp JE, Sisson JC, Eyre PL, Wallis J, Beierwaltes WH. Iodine-131 metaiodobenzylguanidine for the locating of suspected pheochromocytoma: experience in 400 cases. *J Nucl Med* 1985; 26: 576–85.

Naji M, AL-Nahhas A. 68Ga-labelled peptides in the management of neuroectodermal tumours. *Eur J Nucl Med Mol Imaging*. 2012; 39 (Suppl 1): S61-7.

Velikyan I, Sundin A, Sörensen J, Lubberink M, Sandström M, Garske-Román U, et al. Quantitative and qualitative inpatient comparison of 68Ga- DOTATOC and 68Ga-DOTATATE: net uptake rate for accurate quantification. *J Nucl Med*. 2014; 55: 204-10.

Allolio B, Fassnacht M. Clinical review: adrenocortical carcinoma—clinical update. *J Clin Endocrinol Metab* 2006; 91:2027–37.

Bharwani N, Rockall AG, Sahdev A, et al. Adrenocortical carcinoma: the range of appearances on CT and MRI. *AJR* 2011; 196:[web]W706–W714

Korobkin M, Brodeur FJ, Francis IR, Quint LE, Dunnick NR, Londy F. CT time-attenuation washout curves of adrenal adenomas and nonadenomas. *AJR* 1998; 170:747–52.

Becherer A, Vierhapper H, Potzi C, et al. FDGPET in adrenocortical carcinoma. *Cancer Biother Radiopharm* 2001; 16:289–95.

Zhou L, Peng W, Wang C, Liu X, Shen Y, Zhou K. Primary adrenal lymphoma: radiological, pathological, clinical correlation. *Eur J Radiol* 2012; 81:401–5.

Rosenberg SA, Diamond HD, Jaslowitz B, Craver LF. Lymphosarcoma: a review of 1269 cases. *Medicine (Baltimore)* 1961; 40:31–84.

Leite NP, Kased N, Hanna RF, Brown MA, Pereira JM, Cunha R, et al. Cross-sectional imaging of extranodal involvement in abdominopelvic lymphoproliferative malignancies. *Radiographics*. 2007; 27: 1613-34.

Low G, Dhliwayo H, Lomas DJ. Adrenal neoplasms. *Clin Radiol*. 2012; 67: 988-1000.

Chong S, Lee KS, Kim HY, et al. Integrated PET-CT for the characterization of adrenal gland lesions in cancer patients: diagnostic efficacy and interpretation pitfalls. *RadioGraphics* 2006; 26:1811–1824; discussion, 1824–6.

BÖLÜM 4

YAPAY ZEKÂNIN GÖRÜNTÜLEME TEKNİKLERİNE ENTEGRASYONU: TEKNOLOJİK DÖNÜŞÜM VE UYGULAMA ALANLARI

SEDA DEMİR¹

Giriş

Yapay zekâ (YZ), son yıllarda görüntüleme teknolojileri alanında çarpıcı bir dönüşüm yaratmakta ve bu yenilikler yalnızca tıp alanı ile sınırlı kalmayıp otomotiv, güvenlik ve üretim gibi pek çok sektörü de etkilemektedir. [1], [2] Görüntüleme, bir nesnenin ya da yapının görsel temsilini üretmeyi amaçlayan temel bir süreçtir. Bu süreç, YZ'nin sunduğu algoritmik yeteneklerle daha yüksek doğruluk, hız ve verimlilikle gerçekleştirilmekte, böylece insan gözünün ve yorum gücünün ötesinde bir analiz kapasitesi elde edilmektedir.[3]

YZ'nin görüntüleme süreçlerine entegrasyonu, özellikle makine öğrenimi, derin öğrenme ve bilgisayarla görme gibi alt disiplinlerin gelişimiyle mümkün hâle gelmiştir. Bu teknolojiler, görüntü verilerinin işlenmesi, sınıflandırılması ve yorumlanmasında

¹ Öğretim Görevlisi, Doğu Üniversitesi, Meslek Yüksekokulu, Tıbbi Görüntüleme Teknikleri, İstanbul/TÜRKİYE Orcid ID: 0000-0002-8181-2945

önemli rol oynamakta, karar destek sistemlerinin etkinliğini ciddi ölçüde artırmaktadır [4]. Geleneksel görüntüleme yöntemleri olan X-ışını, manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT) ve ultrason, uzun süredir tıpta yaygın olarak kullanılmaktadır. Ancak bu yöntemlerin sınırlı veri işleme ve analiz kabiliyetleri, YZ tabanlı yaklaşımlarla bütünleştirildiğinde belirgin ölçüde gelişmekte, özellikle düşük çözünürlüklü ya da karmaşık vakalarda tanı doğruluğu artmaktadır [5].

YZ destekli görüntüleme sistemleri, yalnızca görsel kaliteyi artırmakla kalmamakta; hastalıkların erken teşhisi, otomatik sınıflandırma, segmentasyon ve anomali tespiti gibi görevlerde de güçlü bir performans sergilemektedir[6]. Bu yönüyle YZ, görüntüleme teknolojilerinde yalnızca teknik bir destek aracı değil, aynı zamanda klinik karar süreçlerinin merkezî bir unsuru hâline gelmektedir.

Bu kitap bölümünde, yapay zekânın görüntüleme teknolojilerine entegrasyonunun teknik, klinik ve toplumsal boyutları bütüncül bir yaklaşımla ele alınacaktır. Ampirik çalışmalar ve modelleme yöntemleri temelinde yapılacak analizler, bu teknolojilerin klinik doğruluk, işlem süresi, maliyet etkinliği ve kullanıcı deneyimi üzerindeki etkilerini değerlendirmeyi amaçlamaktadır. Bunun yanı sıra, algoritmik önyargı, veri mahremiyeti ve etik sorumluluklar gibi konular da ele alınarak, teknolojinin yalnızca faydaları değil, beraberinde getirdiği zorluklar da tartışılacaktır [7].

Böylece bu bölüm, okuyucuya yapay zekâ destekli görüntüleme sistemlerinin sunduğu güncel imkânları ve geleceğe yönelik potansiyel gelişmeleri bilimsel bir zeminde sunmayı hedeflemektedir.

Yapay Zekâya Genel Bakış

Yapay zekâ (YZ), insan zihninin algılama, öğrenme, çıkarım yapma ve problem çözme gibi bilişsel işlevlerini yazılımsal sistemler aracılığıyla taklit etmeyi amaçlayan bir bilgisayar bilimi disiplini [8]. YZ, özellikle makine öğrenimi ve derin öğrenme gibi alt alanlar sayesinde büyük hacimli verilerden örüntüler çıkarma ve bu veriler üzerinde karar destek süreçlerini otomatikleştirme kapasitesine sahiptir [9]. Bu yetkinlik, özellikle görüntüleme sistemleri alanında dikkate değer bir dönüşüm yaratmaktadır. Geleneksel görüntüleme teknikleri—örneğin X-ışını, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG) ve ultrason—uzman yorumu gerektiren, zaman alıcı ve kimi zaman subjektif süreçlere dayanır. Oysa YZ tabanlı sistemler, bu görüntüleri analiz ederek anomali tespiti, sınıflandırma ve öngörü gibi görevleri daha hızlı ve çoğu zaman daha yüksek doğrulukla gerçekleştirebilmektedir. [2] Özellikle derin öğrenme algoritmaları, görüntüdeki karmaşık yapıları tanımlama ve insan gözünün algılayamayacağı düzeyde detayları yorumlama kapasitesiyle, tanısal hassasiyeti artırmaktadır (Esteve et al., 2019). Bu bağlamda, YZ'nin görüntüleme teknolojileriyle entegrasyonu yalnızca teknik bir gelişme olarak değil, sağlık hizmetlerinin kalitesi, endüstriyel denetim süreçleri ve güvenlik uygulamalarında stratejik bir dönüşüm aracı olarak değerlendirilmelidir.

YZ destekli görüntüleme sistemlerinin sunduğu olanaklar, yalnızca teorik değil aynı zamanda ampirik yöntemlerle de doğrulanmaktadır. Özellikle derin öğrenme mimarileri, görüntü sınıflandırma ve segmentasyon gibi temel görevlerde insan performansına eşdeğer ya da üstün sonuçlar üretebilmektedir [10]. Örneğin konvolüsyonel sinir ağları (CNN), tıbbi görüntülerdeki dokusal ve morfolojik farklılıkları tanımlayarak tümör sınıflandırması, organ tanıma veya lezyon tespiti gibi görevlerde yaygın biçimde kullanılmaktadır [11]. Yöntemsel olarak bu

modeller, çok katmanlı yapıları sayesinde ham piksellerden öğrenim yapabilir ve uzman önbilgisine ihtiyaç duymadan karar destek işlevleri üstlenebilir. Bu durum, örüntü tanıma süreçlerini daha az öznelliğe ve daha yüksek tekrarlanabilirliğe kavuşturmaktadır. Literatürde yapılan çok sayıda deneysel çalışma, YZ tabanlı sistemlerin, özellikle BT ve MRG gibi yüksek çözünürlüklü görüntüleme yöntemlerinde duyarlılık ve özgüllük oranlarını anlamlı biçimde artırdığını göstermektedir [5]. Ayrıca, YZ'nin görüntüleme verileri üzerinde eğitilerek tahmin modelleri üretmesi, yalnızca mevcut patolojilerin tanısını değil, hastalıkların olası ilerleyiş senaryolarını öngörme imkânı da sunmaktadır. Bu yöntemsel gelişmeler, görüntüleme sistemlerinin yalnızca statik tanı araçları değil, aynı zamanda proaktif sağlık yönetimi bileşenleri hâline gelmesini sağlamaktadır.

Yapay zekâ (YZ), görüntüleme sistemlerinde yalnızca destekleyici bir araç değil, aynı zamanda analiz, üretim ve iyileştirme süreçlerinde temel belirleyici bir unsur hâline gelmiştir. Görüntü işleme bağlamında YZ uygulamaları üç ana kategoride incelenmektedir: görüntü analizi, görüntü üretimi ve görüntü iyileştirme. Bu üç başlık, YZ'nin görsel verilerle kurduğu etkileşimin yöntemsel temelini oluşturmakta ve özellikle tıp, endüstri, güvenlik ve otomotiv gibi alanlarda görüntüleme teknolojilerinin dönüştürücü gücünü açığa çıkarmaktadır.

Görüntü Analizi

Görüntü analizi, YZ'nin görüntüler üzerinde tanıma, sınıflandırma, segmentasyon ve ölçüm gibi işlemleri otomatik olarak gerçekleştirdiği uygulama alanlarını kapsar.

Bu alandaki uygulamaların en yaygın olduğu sektörlerden biri tıptır. Derin öğrenme algoritmaları, özellikle konvolüsyonel sinir ağları (CNN) aracılığıyla; beyin tümörlerinin sınıflandırılması, akciğer nodüllerinin tespiti, retinal anomalilerin belirlenmesi ve

meme kanseri taramaları gibi çeşitli klinik görevlerde kullanılmaktadır [2]. Bu algoritmalar, görüntülerdeki düşük seviyeli piksellerden başlayarak yüksek seviyeli semantik bilgilere ulaşabilir ve bu bilgileri tanısal karar süreçlerine entegre edebilir. Ayrıca, segmentasyon algoritmaları sayesinde belirli anatomik yapılar ya da patolojik oluşumlar sınırlarıyla birlikte otomatik olarak tanımlanabilir. Bu tür uygulamalar, hem insan hatasını azaltmakta hem de değerlendirme süresini kısaltarak klinik iş akışını hızlandırmaktadır. Örneğin, U-Net gibi mimariler, sınırlı veriyle yüksek doğruluklu biyomedikal segmentasyon yapılmasına olanak tanımaktadır [11]. Görüntü analizi, aynı zamanda üretim hatlarının kalite kontrolü, güvenlik kameralarındaki anomali tespiti ve otonom araçların çevre algılamasında da kritik roller üstlenmektedir.

Görüntü Üretimi

Görüntü üretimi, yapay zekânın mevcut veri setlerinden yeni, sentetik görüntüler oluşturmaya odaklanır. Bu amaçla sıklıkla kullanılan araçların başında Generative Adversarial Networks (GANs) gelmektedir. GAN mimarisi, bir üretici (generator) ve bir ayırt edici (discriminator) olmak üzere iki sinir ağı içerir ve bu ağlar birbirine karşı çalışarak gerçekçiliği yüksek görüntüler üretir. Sağlık alanında, nadir görülen patolojik örneklerin sentetik olarak çoğaltılması, eğitim veri setlerinin dengesini sağlamak ve klinik karar destek sistemlerini geliştirmek açısından büyük önem taşır [12].

Bunun yanı sıra, eksik ya da bozulmuş görüntülerin tamamlanması (image inpainting) ve düşük çözünürlüklü verilerin yüksek çözünürlüklü versiyonlarının tahmin edilmesi gibi uygulamalar da görüntü üretiminin kapsamındadır. Otomotiv sektöründe ise YZ tabanlı simülasyonlar aracılığıyla sanal sürüş senaryoları oluşturulmakta ve bu durum, otonom sistemlerin gerçek dünyaya geçişini hızlandırmaktadır. Görüntü üretimi, ayrıca sanal

gerçeklik (VR), artırılmış gerçeklik (AR) ve dijital medya alanlarında da geniş uygulama alanı bulmaktadır.

Görüntü İyileştirme

Görüntü iyileştirme, mevcut görsel verilerin kalitesini artırmak amacıyla yapay zekâ algoritmalarının kullanıldığı bir diğer önemli alandır. Özellikle düşük dozda çekilen BT (bilgisayarlı tomografi) görüntüleri ya da düşük çözünürlüklü manyetik rezonans görüntüleme (MRG) verileri, teşhis edici nitelik taşımayacak düzeyde bozulma veya gürültü içerebilir. Derin öğrenme tabanlı denoising ve süper çözünürlük (super-resolution) teknikleri, bu tür bozulmaları azaltarak daha net ve anlamlı görüntüler elde edilmesini sağlar[13]. Bunun yanı sıra, kontrast artırımı, bulanıklık giderme ve artefakt düzeltme gibi işlemler de görüntü iyileştirmenin kapsamındadır. Bu yöntemlerin sağlık alanında kullanımı, hem hasta güvenliğini artırmakta (örneğin daha düşük radyasyon dozu) hem de tanı doğruluğunu yükseltmektedir. Ayrıca, endüstriyel uygulamalarda düşük kalite sensör verilerinin işlenebilir hâle getirilmesi, maliyet tasarrufu sağlarken sistem performansını da optimize etmektedir.

Bu üç başlık altında şekillenen yapay zekâ uygulamaları, görüntüleme teknolojilerini yalnızca veri toplama araçları olmaktan çıkarak, yorumlayan, dönüştüren ve öngöründe bulunan dinamik sistemlere dönüştürmektedir.

Her bir uygulama tipi, gerek görsel verinin doğasını anlamada gerekse bu veriden anlamlı bilgi üretmede farklı metodolojik yaklaşımlar sunmakta; bu da görüntüleme sistemlerinin daha güçlü, esnek ve akıllı hâle gelmesini sağlamaktadır.

Veri Setleri ve Ön İşleme

Veri setleri, yapay zekâ (YZ) ile görüntüleme tekniklerinin etkinliğini belirleyen önemli unsurlar olarak değerlendirilmektedir

[14]. YZ sistemlerinin başarı düzeyi, genellikle veri setlerinin kalitesinden ziyade, miktarına bağlı olarak şekillenmektedir [15]. Görüntüleme uygulamaları için gereken veri setleri, tıbbi görüntüler, günlük yaşam kesitleri ya da uzaktan algılama verileri gibi çeşitli kaynaklardan temin edilebilmektedir[16]. Bu verilerin titizlikle toplanması ve etiketlenmesi, modelin eğitim sürecinde büyük önem taşımaktadır. Otomatik etiketleme sistemlerinin yanı sıra uzmanlar tarafından gerçekleştirilen manuel etiketleme, verinin kalitesini artırarak modelin öğrenme yeteneğini geliştirir [17]. Örneğin, tıbbi görüntüler üzerinden hastalık teşhisi yapılacaksa, düzgün bir şekilde etiketlenmiş verilerin varlığı, YZ modelinin karar alma süreçlerini doğrudan etkiler.

Veri ön işleme aşaması, görüntüleri yapay zekâ sistemlerine uygun hale getirmek için gerekli adımları içermektedir. Bu süreç, eksik verilerin tamamlanması, gürültünün azaltılması, görüntülerin ölçeklendirilmesi ve normalleştirilmesi gibi çeşitli yöntemleri kapsar. Görüntüler, genellikle makine öğrenimi algoritmalarının daha verimli çalışması için belirli boyutlara yeniden ayarlanır [15]. Ayrıca, görüntülerin kontrast, parlaklık ve renk dengesi gibi unsurları optimize edilerek modelin performansının artırılması sağlanmaktadır.

Bu adımlar, veri setinin tutarlılığını artırarak modelin genel başarısını olumlu yönde etkilemektedir [16]. Ek olarak, aşırı öğrenme (overfitting) riskini minimize etmek amacıyla veri artırma (data augmentation) teknikleri kullanılarak eğitim setine rastgele varyasyonlar eklenebilir [18]. Örneğin, görüntülerde döndürme veya yansıtma işlemleri gerçekleştirilerek modelin genelleme yeteneği artırılabilir [14].

Sonuç olarak, uygun veri kümelerinin seçimi ve etkili bir ön işleme sürecinin yürütülmesi, yapay zekâ tabanlı görüntüleme yöntemlerinin başarısını artıran önemli faktörlerdir [19]. Eğitim sürecinin başındaki hatalar, modelin performansı üzerinde kalıcı

zararlar yaratabileceğinden, her iki aşamanın da dikkatle tasarlanıp uygulanması gerekmektedir. Bu bağlamda, araştırmacıların ve geliştiricilerin, veri setleri ve ön işleme tekniklerinin geniş yelpazesine ve çeşitliliğine açık olmaları, yapay zekâ modellerinin etkinliğini artırmak için önemli bir fırsat sunmaktadır [20].

Performans Ölçütleri

Performans ölçütleri, yapay zekânın görüntüleme tekniklerinin etkinliğini değerlendirmede önemli bir işlev üstlenmektedir. Bu ölçütler, bir modelin karar verme süreçlerindeki başarısını gösteren sayısal değerler sunmaktadır. Doğruluk, en yaygın ve temel performans ölçütleri arasında yer almaktadır[21].

Doğruluk, modelin doğru bir şekilde tahmin ettiği örneklerin, toplam tahmin sayısına oranı olarak tanımlanır. Ancak, yüksek bir doğruluk oranı modelin genel başarısını her zaman yansıtmayabilir; zira dengesiz veri setlerinde yaygın sınıfın tahmin edilmesi, ayrık sınıflarla ilgili düşük performansın göz ardı edilmesine neden olabilmektedir. Bu bağlamda, diğer ölçütlerin de dikkate alınması gereklidir.

Hassasiyet ve özgüllük, performans değerlendirmesinde dikkate alınması gereken iki temel terimi temsil etmektedir. Hassasiyet, doğru pozitif tahminlerin toplam pozitif tahminlere oranını ifade eder. Özellikle tıbbi görüntüleme uygulamalarında, yanlış negatif sonuçların önlenmesi büyük bir öneme sahiptir; dolayısıyla yüksek bir hassasiyet gerekmektedir. Özgüllük ise, doğru negatif tahminlerin toplam negatif tahminlere oranı şeklinde tanımlanabilir. Önemli bir nokta, yalnızca hassasiyet ve özgüllüğe dayanan karmaşık ölçümlerin, model karşılaştırmalarında daha derin bir anlayış sunmasıdır. Bu iki ölçek, modelin her iki sınıfa karşı gösterdiği etkinliği değerlendirirken, sonuçların bir arada analizi, gerçek dünya uygulamaları açısından daha anlamlı bir bakış açısı sağlar. Sonuç olarak, performans ölçütleri, yapay zekâ ile

görüntüleme tekniklerinin karşılaştırılmasında temel unsurlar olarak öne çıkmaktadır. Doğruluk, hassasiyet ve özgüllük gibi kriterlerin birlikte değerlendirilmesi, yalnızca model başarısını ortaya koymakla kalmaz, aynı zamanda bu modellerin belirli uygulamalardaki etkinliğine dair derinlemesine bir anlayış sunar. Bu çok boyutlu yaklaşımın, geliştiricilerin ve araştırmacıların hangi görüntüleme tekniklerini hangi koşullarda daha etkin kullanabileceklerini anlamalarına yardımcı olduğu aşikardır.

Doğruluk

Doğruluk, görüntüleme tekniklerinin etkinliğini değerlendirmede temel bir performans ölçütü olarak öne çıkmaktadır [22]. Bu kavram, bir modelin veya algoritmanın doğru tahminlerde bulunma oranını ifade etmekte olup genellikle doğru pozitifler ile yanlış pozitiflerin oranından türetilmektedir [23]. Görüntüleme sistemlerinde doğruluk, analiz edilen görüntülerdeki nesnelerin ya da yapıların doğru bir şekilde tanımlanmasını ve sınıflandırılmasını sağlamak açısından kritik bir rol oynamaktadır [24]. Özellikle tıbbi görüntüleme tekniklerinde, örneğin bir tümörün doğru bir şekilde saptanması veya bir lezyonun niteliklerinin belirlenmesi gibi durumlarda, düşük bir doğruluk oranı hastalar üzerinde olumsuz etkiler yaratabileceğinden son derece önemlidir [25]. Görüntüleme tekniklerinin doğruluğunu artırmak için algoritmaların optimize edilmesi, verilerin çeşitlendirilmesi ve model eğitiminin iyileştirilmesi gereklidir [26]. Yapay zekâ tabanlı sistemler, makine öğrenimi ve derin öğrenme algoritmalarının uygulanmasıyla önemli bir gelişim göstermektedir [27]. Bu sistemler, büyük ölçekli verilerden öğrenme yetenekleri sayesinde hata oranlarını minimize etme potansiyeline sahiptir. Örneğin, bir derin öğrenme modeli, eğitim verileri üzerinde gerçekleştirilecek döngüsel öğrenme süreçleri ile daha önce gözlemlenmemiş örüntüleri keşfederek görüntülerdeki hataları daha etkin bir şekilde tespit edebilir. Bu tür gelişmeler, doğru sonuçların elde edilmesinin yanı sıra, görüntüleme

sonuçlarının yorumlanmasında da güvenilirlik sağlar [28]. Ancak, doğruluk değerlendirmelerinde doğrulama setlerinin seçimi, modelin genellenebilirliği ve aşırı öğrenme gibi faktörlerin de göz önünde bulundurulması gereklidir [29]. Örneğin, yüksek doğruluk oranları, modelin öğrenilmiş verilere aşırı bağımlı olduğu durumlarda yanıltıcı olabilmektedir. Bu nedenle, çeşitli veri setleri ve senaryolar üzerindeki testler, modelin dayanıklılığını ve gerçek dünya koşullarındaki başarısını artırmak için kritik bir gereklilik olarak ortaya çıkmaktadır [30]. Böylece, yapay zekâ ile görüntüleme tekniklerinin doğruluk düzeyi, hastalıkların erken teşhisi ve klinik karar verme süreçleri üzerinde doğrudan etkili hale gelmektedir. Doğruluğun sürekli olarak artırılması, sağlık hizmetleri ve diğer endüstrilere yönelik görüntüleme uygulamalarının başarısını belirlemede en önemli göstergelerden biri olmaya devam edecektir [31].

Hassasiyet

Hassasiyet, bir makine öğrenimi modelinin pozitif sınıfı doğru şekilde tespit etme yeteneğini ölçen önemli bir performans göstergesidir [32]. Özellikle sınıflandırma problemlerinde büyük bir öneme sahip olan hassasiyet, yanlış pozitif sonuçların sayısını en aza indirmek amacıyla çeşitli yöntemler ile değerlendirilebilir. Bir modelin hassasiyeti, doğru pozitiflerin toplam tahmin edilen pozitiflere oranı olarak tanımlanır [33]. Bu metrik, tıbbi görüntüleme ve dolandırıcılık tespiti gibi alanlarda, yanlış pozitiflerin ciddi sonuçlar doğurabileceği durumlarda hayati bir rol oynamaktadır [34]. Hassasiyetin hesaplanması, modelin güvenilirliğini artırmak açısından kritik bir adımdır. Ancak, hassasiyet tek başına bir modelin başarısını belirlemez; doğruluk ve özgüllük gibi diğer performans ölçütleri ile birlikte değerlendirilmesi gerekmektedir [35]. Yüksek bir hassasiyet değeri, saptanan yanlış pozitifler nedeniyle yanıltıcı olabilir, bu yüzden modelin genel performansını anlamak için hassasiyetin yanı sıra diğer metriklerin de dikkate alınması şarttır

[36]. Bazı durumlarda, hassasiyeti artırmak için modelin karmaşıklığının artırılması, veri setinin genişletilmesi veya farklı algoritmaların entegrasyonu gibi stratejilerin benimsenmesi mümkündür. Ancak bu durum, yüksek özgüllük değerlerinden ödün verilmesi anlamına gelebilir [36]. Hassasiyetin artırılmasına yönelik uygulamalar, yapay zekâ ve makine öğrenimi sistemlerinde önemli bir araştırma alanı haline gelmiştir [36]. Derin öğrenme teknikleri ve transfer öğrenme yöntemleri, görüntüleme verilerinin daha iyi anlaşılmasını sağlayarak, hassasiyetin artırılmasına katkıda bulunur [37]. Gelişmiş model tasarımı ve algoritmalar, sistemin genel doğruluğunu artırarak, yanlış pozitiflerin azaltılmasına yönelik daha etkili yollar sunar.

Bu nedenle, uygulanan tekniklerin etkililiğinin sürekli olarak gözlemlenmesi ve gerektiğinde ayarlamalar yapılması, yapay zekâ ile görüntüleme sistemlerinin başarısını sağlamak açısından kritik bir öneme sahiptir [38].

Özgüllük

Özgüllük, tıbbi görüntüleme teknikleri ve yapay zekâ uygulamalarında, belirli bir pozitif sonucu doğru bir şekilde tanımlama yeteneğine işaret eder [39]. Bir sistemin özgüllüğü, yanlış pozitif sonuçlarla doğru negatif sonuçların oranını ölçen bir performans ölçütü olarak kritik bir anlam taşır. Özgüllük, genellikle bir aletin, testin veya algoritmanın belirli bir durumun mevcut olmadığını ne ölçüde etkili bir şekilde tespit edebildiğini gösterir. Bu açıdan, yüksek bir özgüllük oranı klinik uygulamalarda hatalı sonuçların sayısını minimize etmekte önemli bir rol oynar. Özellikle sağlık alanında, görüntüleme teknikleriyle birlikte kullanılan yapay zekâ algoritmalarının özgüllüğü, hastalıkların teşhisinde kritik bir öneme sahiptir. Örneğin, kanser tarama sistemlerinde yüksek özgüllüğe sahip bir model, kanser olmayan bireyleri doğru bir şekilde ayırt ederek gereksiz endişeleri ve ilave test gereksinimlerini

azaltır [40]. Ayrıca, bilgisayarla desteklenen radyoloji sistemlerinde yapay zekâ tabanlı algoritmaların eğitimi sırasında özgüllük, modelin eğitildiği veri setlerinin kalitesine ve çeşitliliğine bağlıdır. Verilerin temsili ve seçilmesi, özgüllüğü etkileyen önemli unsurlardandır [41]. Özgüllük ile birlikte değerlendirilecek bir diğer önemli kavram hassasiyettir. Sağlık uygulamalarında yalnızca özgüllüğe odaklanmak yetersiz kalabilir; yüksek özgüllüğe sahip bir sistem belirli hastalıkların bulunabilirliğini yeterince değerlendiremeyebilir. Bu nedenle, özgüllük ve hassasiyet arasında bir denge sağlamak, daha bütüncül bir değerlendirme gerektirir. Yapay zekâ ile desteklenen görüntüleme tekniklerinin geliştirilmesi, bu özgüllük ve hassasiyet dengesini optimize etme üzerine odaklanmalıdır. Bu durum, genel olarak sağlık hizmetlerinin kalitesini artırmak ve doğru tanı süreçlerini hızlandırmak açısından hayati bir önem taşımaktadır [42]

Tıbbi Görüntüleme Teknikleri

Tıbbi görüntüleme, sağlık hizmetleri içerisinde hastalıkların teşhis edilmesi ve izlenmesi açısından kritik bir rol oynamaktadır. Bu alan, kapsamlı bir gelişim süreci geçirerek geleneksel görüntüleme tekniklerinden modern yapay zekâ (YZ) destekli yöntemlere geçiş yapmıştır. Bu dönüşüm, tanı süreçlerinin hızını, doğruluğunu ve güvenilirliğini artırarak sağlık hizmetlerinin kalitesini önemli ölçüde yükseltmiştir [43]. Ultrason, manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT) ve pozitron emisyon tomografisi (PET) gibi görüntüleme yöntemleri, iç organların, dokuların ve hücrelerin değerlendirilmesinde yaygın olarak kullanılmaktadır [41]. Yapay zekâ algoritmalarının tıbbi görüntüleme süreçlerine entegrasyonu, görüntülerin analizi ve yorumlanmasında önemli yenilikler getirmiştir. Özellikle derin öğrenme teknikleri, büyük veri setlerini kullanarak görüntülerdeki hastalıklı lezyonların tespitinde ve sınıflandırılmasında insan uzmanlarını geride bırakabilecek bir düzeye ulaşmıştır [44]. YZ

tabanlı sistemler, hastalıkların erken teşhis edilebilmesi amacıyla optimize edilebilir; böylece görüntüleme süreçlerinin verimliliği artırılabilir [45].

Bu sistemlerin zamanla daha zeki hale gelmesi, geçmiş tıbbi verilerin, genetik özelliklerin ve biyomarker bilgilerin analizi sayesinde mümkün hale gelmektedir [46]. Sonuç olarak, daha bireyselleştirilmiş ve kapsamlı sağlık hizmetleri sunma kapasitesi artmaktadır.

Yapay zekâ algoritmaları, spesifik hastalıkların teşhisinde, görüntülerdeki ince detayları dikkate alarak, gözden kaçabilecek olası anomalileri belirleme yeteneği taşımaktadır. Bu tür gelişmeler, tıbbi karar alma süreçlerinin daha güvenilir ve etkin bir şekilde yürütülmesine zemin hazırlamaktadır. Ayrıca, yapay zekâ destekli tıbbi görüntüleme sistemlerinin, sağlık hizmeti maliyetlerini düşürme potansiyeli de dikkat çekmektedir. Daha hızlı ve doğru tanımlar sayesinde gereksiz işlemler önlenebilir ve tedavi süreçleri hızlanarak daha etkili hale getirilmektedir. Gelecekte, tıbbi görüntülemedeki yapay zekâ uygulamalarının etkisi giderek artacak ve sağlık sistemlerinin işleyişini daha verimli hale getirecektir. Tüm bu unsurlar, yapay zekâ ile tıbbi görüntüleme tekniklerinin karşılaştırılmasında göz önünde bulundurulması gereken kritik faktörler arasında yer almaktadır. Hem hastalar hem de sağlık profesyonelleri açısından sağlanan bu yenilikler, sağlık sektöründe devrim niteliğinde bir değişimin kapılarını aralayabilir [47].

Görüntüleme Tekniklerinin Karşılaştırılması

Görüntüleme teknikleri, modern yapay zekâ uygulamalarında temel bir rol oynamaktadır ve çeşitli alanlarda verimlilik, doğruluk ve hız artırmaya yardımcı olmaktadır. Bu bölümde, farklı görüntüleme tekniklerinin karşılaştırılması, her birinin avantajları ve dezavantajları doğrultusunda gerçekleştirilecektir. Genellikle, görüntüleme teknikleri üç ana

kategoride incelenir: klasik görüntüleme yöntemleri, dijital görüntü işleme ve yapay zekâ destekli yöntemler. Klasik yöntemler arasında Röntgen, ultrason ve manyetik rezonans görüntüleme (MRG) gibi teknikler yer alırken, dijital görüntüleme muayene sonuçlarının hızlı bir şekilde elde edilmesini sağlar; bunun yanında görüntüleme sürecinin kalitesini artıracak araçlar sunar.

Yapay zekâ destekli görüntüleme ise, görüntüleri analiz etmek, sınıflandırmak ve yorumlamak için algoritmalar kullanarak daha derinlemesine içgörüler sunmakta, böylece hem tanı süreçlerini hızlandırmakta hem de insan hatalarını azaltmaktadır.

Klasik görüntüleme tekniklerinin fonksiyonları arasında görüntülerin fiziksel ortamda oluşturulması ve gözlemlenmesi yer alırken, dijital yöntemler esneklik sağlamaktadır. Örneğin, dijital görüntü işleme, verilerin işlenmesi, saklanması ve paylaşılmasını kolaylaştırmanın yanı sıra, çeşitli algoritmaların uygulanmasına da olanak tanımaktadır. Öte yandan, yapay zekâ tabanlı yöntemler, özellikle derin öğrenme teknikleri kullanarak büyük veri setlerinden öğrenme yeteneğine sahiptir. Bu, özellikle sağlık sektöründe, hastalıkların erken teşhisi ve tanı süreçlerinin optimize edilmesi açısından büyük bir fark yaratmaktadır. Kısacası, yapay zekâ, görüntüleme tekniklerinin doğruluğunu ve etkinliğini arttırarak, karmaşık sorunları çözme kapasitesini büyük ölçüde geliştirmektedir.

Görüntüleme tekniklerinin karşılaştırılması sürecinde, her bir yöntemin kullanım alanları ve sektörel uygulamaları da önem kazanmaktadır. Örneğin, klasik görüntüleme yöntemleri genellikle belirli hastalıkların teşhisinde standartlaşmış olsa da, yapay zeka destekli yöntemler, hastaların bireysel özelliklerine daha iyi yanıt verebilecek kişiselleştirilmiş çekim ve analiz yöntemleri sunmaktadır. Dolayısıyla, görüntüleme tekniklerinin seçiminde, elde edilmek istenen sonuçlar ve belirli durumların gereksinimleri göz önüne alınmalı, bu süreçte hangi tekniğin uygulanacağına dair

verimli bir analiz yapılmalıdır. Böylelikle, bu karşılaştırmalar sayesinde, sağlık hizmetlerinden eğitim sektörüne kadar geniş bir yelpazede en uygun görüntüleme yöntemlerinin belirlenmesi mümkün olacaktır [48].

Yapay Zekâ ile Görüntüleme Tekniklerinin Avantajları

Yapay zekâ (YZ) teknolojilerinin tıbbi görüntüleme yöntemlerine entegrasyonu, modern sağlık hizmetlerinde önemli dönüşümlere yol açmaktadır. YZ algoritmaları, özellikle büyük hacimli ve karmaşık verilerin analizinde sağladığı yüksek işlem kapasitesi sayesinde, görüntüleme verilerinin daha hızlı ve güvenilir biçimde değerlendirilmesine olanak tanımaktadır [2]. Bu bağlamda, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi yöntemlerle elde edilen görüntülerin YZ tabanlı sistemlerle analiz edilmesi, erken tanı olasılığını artırmakta ve tedavi sürecine zaman kazandırmaktadır [1]. YZ'nin özellikle radyoloji alanındaki katkıları, yalnızca iş yükünün azaltılması ile sınırlı kalmamakta; aynı zamanda teşhis doğruluğunun da artmasına katkı sunmaktadır. Derin öğrenme algoritmaları, patolojik bulguların sınıflandırılması ve daha önce fark edilmemiş anomalilerin belirlenmesinde önemli başarılar sergilemektedir [3]. Özellikle onkolojik görüntülemede, malignite olasılıklarının yüksek doğrulukla tespit edilmesi sayesinde, tedavi planlamasında daha etkili ve bireyselleştirilmiş yaklaşımlar geliştirilebilmektedir [49].

Bununla birlikte, YZ tabanlı sistemlerin öğrenmeye açık yapısı, zaman içerisinde performanslarının artmasına olanak tanımaktadır. Bu durum, sistemlerin sahada daha etkin kullanılabilmesi ve klinik karar destek sistemleriyle entegre biçimde çalışabilmesi açısından önemli bir avantajdır [6]. Ayrıca, otomasyonun artırılmasıyla birlikte, uzmanlık gerektiren işlemlerde insan kaynaklı hata payı azaltılmakta ve sağlık hizmetlerinin kalitesi artırılmaktadır.

Ekonomik ve lojistik boyutlar açısından değerlendirildiğinde, YZ'nin sunduğu otomasyon yetenekleri, sağlık sistemleri için maliyetleri düşürme ve hizmete erişimi genişletme potansiyeli taşımaktadır [50]. Bu durum, özellikle sınırlı uzman erişimi olan bölgelerde görüntüleme hizmetlerinin daha yaygın biçimde sunulmasını mümkün kılmaktadır.

Sonuç olarak, yapay zekâ teknolojilerinin tıbbi görüntüleme yöntemlerine entegrasyonu, tanı ve tedavi süreçlerinde devrim niteliğinde gelişmelere kapı aralamaktadır. Söz konusu entegrasyon, sadece mevcut sistemlerin etkinliğini artırmakla kalmayıp, aynı zamanda gelecekte sağlık hizmetlerinin daha erişilebilir, hızlı ve etkili hâle gelmesini de mümkün kılmaktadır.

Yapay Zekâ Destekli Görüntüleme Tekniklerinin Sınırlılıkları ve Zorlukları

Yapay zekâ (YZ) teknolojileri, görüntü işleme ve analiz süreçlerinde çığır açıcı gelişmelere olanak tanımış olmakla birlikte, bu sistemlerin uygulanmasında çeşitli sınırlılıklar ve zorluklar da mevcuttur. Öncelikli sorunlardan biri, YZ algoritmalarının yüksek doğrulukla çalışabilmesi için geniş ve nitelikli veri setlerine gereksinim duymasındır. Kullanılan veri kümelerinin demografik çeşitliliği yeterince yansıtmaması, örneğin yaş, cinsiyet veya etnik köken gibi değişkenlerde dengesizliklerin bulunması, modelin önyargılı veya hatalı sonuçlar üretmesine neden olabilmektedir [51]. Özellikle sağlık hizmetlerinde bu tür önyargılar, yanlış teşhislere veya uygunsuz tedavi stratejilerine yol açarak ciddi etik ve klinik sorunlar doğurabilir.

Bir diğer önemli sınırlılık ise YZ sistemlerinin açıklanabilirlik düzeyinin düşüklüğüdür. Çoğu derin öğrenme algoritması, “kara kutu” olarak nitelendirilen bir yapıda çalışmakta, bu da sistemin nasıl karar verdiğini açıkça ortaya koyamamaktadır [52]. Bu durum, özellikle sağlık profesyonelleri açısından

algoritmaların çıktılarının güvenilirliğini sorgulamalarına neden olmakta; sonuçların yorumlanabilirliğini azaltarak klinik karar süreçlerini belirsiz hale getirebilmektedir [53]. Ayrıca, açıklanabilirliğin yetersizliği, sistemsel hataların kaynağını belirlemeyi zorlaştırmakta ve yasal-sorumluluk mekanizmalarında karmaşıklığa yol açmaktadır.

Bununla birlikte, YZ tabanlı görüntüleme uygulamalarının teknik altyapı gereksinimleri de yaygın kullanımın önünde bir engel oluşturmaktadır. Derin öğrenme algoritmalarının eğitimi ve çalıştırılması, yüksek işlem gücü ve enerji tüketimi gerektirdiğinden, bu tür sistemlerin küçük ölçekli sağlık kuruluşları tarafından benimsenmesi sınırlı kalabilmektedir [54]. Maliyetlerin yüksekliği, sadece altyapı değil aynı zamanda bakım, yazılım güncellemeleri ve veri güvenliği gibi alanlarda da uzun vadeli yatırımlar gerektirmektedir.

Sonuç olarak, YZ destekli görüntüleme teknolojileri, önemli avantajlar sunmakla birlikte, veri temelli önyargılar, açıklanabilirlik sorunları ve teknik/mali kısıtlar gibi önemli dezavantajlar da barındırmaktadır. Bu nedenle, söz konusu teknolojilerin daha adil, şeffaf ve erişilebilir hale getirilmesi yönünde çalışmalar yapılması büyük önem taşımaktadır. Gelecekte, yapay zekânın etik, teknik ve sosyoekonomik boyutlarının bütüncül bir şekilde ele alınması, bu teknolojilerin sağlık alanındaki etkisini daha sürdürülebilir kılacaktır.

Sonuç

Yapay zekâ (YZ) teknolojilerinin görüntüleme alanına entegrasyonu, bu alanda kaydedilen ilerlemelerin çeşitliliğini ve uygulama potansiyelini gözler önüne sermektedir. Derin öğrenme gibi gelişmiş algoritmalar sayesinde, görüntülerin işlenmesi ve sınıflandırılması daha yüksek doğruluk oranlarıyla gerçekleştirilebilmekte; bu durum özellikle tıp, otomotiv ve güvenlik

gibi kritik sektörlerde hata oranlarının azaltılmasına katkı sunmaktadır [2]. Geleneksel görüntüleme yöntemleriyle karşılaştırıldığında, YZ tabanlı sistemler hem hız hem de detay analizi açısından önemli avantajlar ortaya koymuştur. Bu karşılaştırmalı süreçte, farklı YZ modellerinin ve klasik görüntüleme tekniklerinin performans ölçütleri değerlendirilmiştir. Yapılan çalışmalar, derin öğrenme modellerinin, özellikle büyük ve yüksek kaliteli veri kümeleriyle eğitildiğinde, anomali tespiti ve görüntü iyileştirme gibi görevlerde geleneksel yöntemlere kıyasla daha başarılı sonuçlar verdiğini göstermektedir [1]. Nitekim, bazı YZ sistemleri, insan gözünün ayırt edemeyeceği mikro düzeydeki detayları ortaya çıkararak tanısal doğruluğu artırabilmektedir [3]. Bununla birlikte, geleneksel görüntüleme tekniklerinin bazı avantajlarını koruduğu da unutulmamalıdır. Özellikle sınırlı, eksik ya da hatalı veri ile çalışıldığında, makine öğrenimi tabanlı sistemler yeterince iyi genelleme yapamayabilirken, konvansiyonel yöntemler bu gibi durumlarda daha kararlı sonuçlar verebilmektedir[6]. Bu durum, her iki yaklaşımın da belirli koşullar altında farklı üstünlüklere sahip olduğunu göstermektedir.

Sonuç olarak, yapay zekâ ile görüntüleme teknolojilerinin entegrasyonu, yalnızca mevcut görüntüleme pratiklerini daha işlevsel hale getirmekle kalmamakta, aynı zamanda alanın inovatif dönüşümünü hızlandırmaktadır. Bu teknolojilerin sürekli olarak optimize edilmesi ve farklı alanlara entegre edilmesiyle birlikte, sağlık hizmetlerinin kalitesinin artırılması, endüstriyel üretkenliğin yükseltilmesi ve güvenlik sistemlerinin daha akıllı hale getirilmesi mümkün olabilecektir [55].

YZ ve görüntüleme teknolojilerinin kesişim noktasında yer alan bu dönüşüm süreci, önümüzdeki yıllarda dijitalleşme ve otomasyonun merkezinde yer alarak teknolojik evrime yön verecektir. Bu bağlamda, multidisipliner araştırmaların

desteklenmesi ve etik, teknik ile uygulama boyutlarının dengeli biçimde ele alınması büyük önem taşımaktadır.

Kaynakça

- [1] A. Esteva et al., “A guide to deep learning in healthcare,” Jan. 01, 2019, Nature Publishing Group. doi: 10.1038/s41591-018-0316-z.
- [2] G. Litjens et al., “A survey on deep learning in medical image analysis,” *Med Image Anal*, vol. 42, pp. 60–88, Dec. 2017, doi: 10.1016/j.media.2017.07.005.
- [3] D. Shen, G. Wu, and H.-I. Suk, “Deep Learning in Medical Image Analysis,” *Annu Rev Biomed Eng*, vol. 19, no. 1, pp. 221–248, Jun. 2017, doi: 10.1146/annurev-bioeng-071516-044442.
- [4] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” May 27, 2015, Nature Publishing Group. doi: 10.1038/nature14539.
- [5] A. S. Lundervold and A. Lundervold, “An overview of deep learning in medical imaging focusing on MRI,” *Z Med Phys*, vol. 29, no. 2, pp. 102–127, May 2019, doi: 10.1016/j.zemedi.2018.11.002.
- [6] E. J. Topol, “High-performance medicine: the convergence of human and artificial intelligence,” Jan. 01, 2019, Nature Publishing Group. doi: 10.1038/s41591-018-0300-7.
- [7] D. S. Char, N. H. Shah, and D. Magnus, “Implementing Machine Learning in Health Care — Addressing Ethical Challenges,” *New England Journal of Medicine*, vol. 378, no. 11, pp. 981–983, Mar. 2018, doi: 10.1056/NEJMp1714229.
- [8] A. Creswell, T. White, V. Dumoulin, K. Arulkumaran, B. Sengupta, and A. A. Bharath, “Generative Adversarial Networks: An Overview,” *IEEE Signal Process Mag*, vol. 35, no. 1, pp. 53–65, Jan. 2018, doi: 10.1109/MSP.2017.2765202.

[9] K. G. Kim, “Book Review: Deep Learning,” *Healthc Inform Res*, vol. 22, no. 4, p. 351, 2016, doi: 10.4258/hir.2016.22.4.351.

[10] D. Shen, G. Wu, and H.-I. Suk, “Deep Learning in Medical Image Analysis,” *Annu Rev Biomed Eng*, vol. 19, no. 1, pp. 221–248, Jun. 2017, doi: 10.1146/annurev-bioeng-071516-044442.

[11] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Verlag, 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.

[12] M. Frid-Adar, I. Diamant, E. Klang, M. Amitai, J. Goldberger, and H. Greenspan, “GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification,” *Neurocomputing*, vol. 321, pp. 321–331, Dec. 2018, doi: 10.1016/j.neucom.2018.09.013.

[13] C. Chen, S. Zhao, A. Karnad, and J. W. Freeman, “The biology and role of CD44 in cancer progression: Therapeutic implications,” May 10, 2018, BioMed Central Ltd. doi: 10.1186/s13045-018-0605-5.

[14] H. ÖZTÜRK, “Arşivler ve Yapay Zekâ,” *Bilgi Yönetimi*, vol. 4, no. 2, pp. 283–300, Dec. 2021, doi: 10.33721/by.987197.

[15] D. Boz Eravcı, “Kurumların Dijital Dönüşümü: Büyük Veri Regimes Digital Transformation of Institutions: Big Data,” vol. 1, no. 1, pp. 90–112, 2020, [Online]. Available: www.dergipark.org.tr/cider

[16] H. HOŞGÖR and H. GÜNGÖRDÜ, “Sağlıkta Yapay Zekanın Kullanım Alanları Üzerine Nitel Bir Araştırma,” *European*

Journal of Science and Technology, Apr. 2022, doi: 10.31590/ejosat.1052614.

[17] N. TEKİN, “Eğitimde Yapay Zekâ: Türkiye Kaynaklı Araştırmaların Eğilimleri Üzerine Bir İçerik Analizi,” Necmettin Erbakan Üniversitesi Eregli Eğitim Fakültesi, Necmettin Erbakan University, Oct. 2023, doi: 10.51119/ereegf.2023.49.

[18] E. ALİMOVSKİ and G. ERDEMİR, “Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi,” İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi, vol. 3, no. 1, pp. 76–80, Apr. 2021, doi: 10.47769/izufbed.880581.

[19] “10.7822-omuefd.1293657-3127577”.

[20] C. Özdemir, “Derin Öğrenme Modelleri ve Veri Ön İşleme Yöntemleri ile Çeltik Yaprak Hastalıklarının Erken Teşhisi,” 2023.

[21] “Beyin T__m__r Tespiti ____in Derin ____renme Temelli Bilgisayar Destekli Tan__ Sistemi[#1005401]-2012285”.

[22] A. Singha, R. S. Thakur, and T. Patel, “Deep Learning Applications in Medical Image Analysis,” in Biomedical Data Mining for Information Retrieval, Wiley, 2021, pp. 293–350. doi: 10.1002/9781119711278.ch11.

[23] M. P. Recht et al., “Integrating artificial intelligence into the clinical practice of radiology: challenges and recommendations,” Eur Radiol, vol. 30, no. 6, pp. 3576–3584, Jun. 2020, doi: 10.1007/s00330-020-06672-5.

[24] C. Jin et al., “Object recognition in medical images via anatomy-guided deep learning,” Med Image Anal, vol. 81, p. 102527, Oct. 2022, doi: 10.1016/j.media.2022.102527.

[25] J. H. Park et al., “Artificial Intelligence for Predicting Microsatellite Instability Based on Tumor Histomorphology: A Systematic Review,” *Int J Mol Sci*, vol. 23, no. 5, p. 2462, Feb. 2022, doi: 10.3390/ijms23052462.

[26] J. Zhang, L. Xiao, Y. Zhang, J. Lai, and Y. Yang, “Frontiers in Computing and Intelligent Systems Optimization and Performance Evaluation of Deep Learning Algorithm in Medical Image Processing”.

[27] A. Karargyris et al., “Federated benchmarking of medical artificial intelligence with MedPerf,” *Nat Mach Intell*, vol. 5, no. 7, pp. 799–810, Jul. 2023, doi: 10.1038/s42256-023-00652-2.

[28] M. A. Davis, B. Rao, P. A. Cedeno, A. Saha, and V. M. Zohrabian, “Machine Learning and Improved Quality Metrics in Acute Intracranial Hemorrhage by Noncontrast Computed Tomography,” *Curr Probl Diagn Radiol*, vol. 51, no. 4, pp. 556–561, Jul. 2022, doi: 10.1067/j.cpradiol.2020.10.007.

[29] P. Xuan Lam, P. Q. H. Mai, Q. H. Nguyen, T. Pham, T. H. H. Nguyen, and T. H. Nguyen, “Enhancing educational evaluation through predictive student assessment modeling,” *Computers and Education: Artificial Intelligence*, vol. 6, p. 100244, Jun. 2024, doi: 10.1016/j.caeai.2024.100244.

[30] M. Lopez and S. Martinez, “Adversarial Training and Beyond Approaches for Improving Deep Learning Model Robustness,” 2023.

[31] S. Kumar and A. Dawani, “DEEP LEARNING FOR RADIOLOGY: IMPROVING DIAGNOSTIC ACCURACY IN MEDICAL IMAGING,” *Spectrum of Engineering and Management Sciences*, vol. 2, pp. 517–533, Dec. 2024, doi: 10.5281/zenodo.15341712.

[32] J. Davis and M. Goadrich, “The relationship between Precision-Recall and ROC curves,” in Proceedings of the 23rd international conference on Machine learning - ICML '06, New York, New York, USA: ACM Press, 2006, pp. 233–240. doi: 10.1145/1143844.1143874.

[33] M. Sokolova and G. Lapalme, “A systematic analysis of performance measures for classification tasks,” *Inf Process Manag*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/j.ipm.2009.03.002.

[34] K. Zou, Z. Chen, X. Yuan, X. Shen, M. Wang, and H. Fu, “A review of uncertainty estimation and its application in medical imaging,” *Meta-Radiology*, vol. 1, no. 1, p. 100003, Jun. 2023, doi: 10.1016/j.metrad.2023.100003.

[35] A. Panesar, “Evaluating Machine Learning Models,” in *Machine Learning and AI for Healthcare*, Berkeley, CA: Apress, 2021, pp. 189–205. doi: 10.1007/978-1-4842-6537-6_7.

[36] J. Wang, F. Zhou, S. Wen, X. Liu, Y. Lin, and B. Research, “Deep Metric Learning with Angular Loss.”

[37] Y. Hu, W. Guo, Z. Xu, and C. Shi, “Physics knowledge-based transfer learning between buildings for seismic response prediction,” *Soil Dynamics and Earthquake Engineering*, vol. 177, p. 108420, Feb. 2024, doi: 10.1016/j.soildyn.2023.108420.

[38] N. Muralidharan, S. Gupta, M. R. Prusty, and R. K. Tripathy, “Detection of COVID19 from X-ray images using multiscale Deep Convolutional Neural Network,” *Appl Soft Comput*, vol. 119, p. 108610, Apr. 2022, doi: 10.1016/j.asoc.2022.108610.

[39] E. Gümüþ and E. Uysal Kasap, “Saęlık Ekosisteminde Yapay Zeka Kaygı Düzeyi: Hemþire Örneklemi,”

Journal of Artificial Intelligence in Health Sciences, vol. 2, no. 3, pp. 1–7, Dec. 2022, doi: 10.52309/jaihs.v2i2.43.

[40] B. VATANSEVER, H. AYDIN, and A. ÇETİNKAYA, “Genetik Algoritma Yaklaşımıyla Öznitelik Seçimi Kullanılarak Makine Öğrenmesi Algoritmaları ile Kalp Hastalığı Tahmini,” Journal of Scientific Technology and Engineering Research, Nov. 2021, doi: 10.53525/jster.1005934.

[41] R. Najjar, “Redefining Radiology: A Review of Artificial Intelligence Integration in Medical Imaging,” Diagnostics, vol. 13, no. 17, p. 2760, Aug. 2023, doi: 10.3390/diagnostics13172760.

[42] B. Ö. Ktabı, III. SAĞLIK HİZMETLERİNDE YENİLİKLER VE TEKNOLOJİ SEMPOZYUMU. [Online]. Available: <https://isni.org/isni/0000000040369655X>

[43] HASTANE VE SAĞLIK YÖNETİMİ: GÜNCEL KONULAR-II. 2023. [Online]. Available: www.iksadyayinevi.com

[44] D. Öğrenme et al., “MAKALE BİLGİSİ ÖZET,” 2017.

[45] T. TOSUN İstanbul Aydın Üniversitesi et al., “İSTANBUL AYDIN UNIVERSITY JOURNAL OF FACULTY OF DENTISTRY AYDIN DENTAL Graphic Design-Grafik Tasarım Başak GÜNDÜZ Editorial Board-Yayın Kurulu”, [Online]. Available: www.aydin.edu.tr

[46] B. ÇETİN, “SAĞLIK HİZMETLERİ VE YAPAY ZEKA,” Uluslararası Ekonomi ve Siyaset Bilimleri Akademik Araştırmalar Dergisi, vol. 7, no. 17, pp. 53–67, Oct. 2023, doi: 10.58202/joecopol.1364565.

[47] E. M. Hakan YALÇINKAYA and İ. Dilber, SAĞLIK EKONOMİSİ “Sağlıkta Dönüşüm ve Fırsatlar.” 2020. [Online]. Available: www.iksadyayinevi.com

[48] H. Gülbiçim and A. R. Yusuf, “New Imaging Technologies and Software in Nuclear Cardiology,” *Nuclear Medicine Seminars*, vol. 10, no. 1, pp. 1–12, Apr. 2024, doi: 10.4274/nts.galenos.2024.0001.

[49] D. Ardila et al., “End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography,” *Nat Med*, vol. 25, no. 6, pp. 954–961, Jun. 2019, doi: 10.1038/s41591-019-0447-x.

[50] F. Jiang et al., “Artificial intelligence in healthcare: Past, present and future,” Dec. 01, 2017, BMJ Publishing Group. doi: 10.1136/svn-2017-000101.

[51] M. Ghassemi, L. Oakden-Rayner, and A. L. Beam, “The false hope of current approaches to explainable artificial intelligence in health care,” *Lancet Digit Health*, vol. 3, no. 11, pp. e745–e750, Nov. 2021, doi: 10.1016/S2589-7500(21)00208-9.

[52] Z. C. Lipton, “The mythos of model interpretability,” *Commun ACM*, vol. 61, no. 10, pp. 36–43, Sep. 2018, doi: 10.1145/3233231.

[53] W. Samek, T. Wiegand, and K.-R. Müller, “Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models,” Aug. 2017, [Online]. Available: <http://arxiv.org/abs/1708.08296>

[54] J. He, S. L. Baxter, J. Xu, J. Xu, X. Zhou, and K. Zhang, “The practical implementation of artificial intelligence technologies in medicine,” Jan. 01, 2019, Nature Publishing Group. doi: 10.1038/s41591-018-0307-0.

[55] P. Rajpurkar et al., “Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists,” *PLoS Med*, vol. 15, no. 11, p. e1002686, Nov. 2018, doi: 10.1371/journal.pmed.1002686.

TÜMÖRLER VE YAPAY ZEKAYA GÜNCEL RADYOLOJİK YAKLAŞIM

