

KLİNİK YÖNETİMDE YAPAY ZEKA DESTEKLİ YAKLAŞIMLAR

Editör

Prof. Dr. Yakup BAYKUŞ

Doç. Dr. Rulin DENİZ

Dr. Öğr. Üyesi Alihan TIĞLI

yaz
yayınları



Klinik Yönetimde Yapay Zeka Destekli Yaklaşımlar

Editör

Prof. Dr. Yakup BAYKUŞ

Doç. Dr. Rulin DENİZ

Dr. Öğr. Üyesi Alihan TIĞLI

yaz
yayınları

2026

Klinik Yönetimde Yapay Zeka Destekli Yaklaşımlar

Editör: Prof. Dr. Yakup BAYKUŞ

Doç. Dr. Rulin DENİZ

Dr. Öğr. Üyesi Alihan TIĞLI

© YAZ Yayınları

Bu kitabın her türlü yayın hakkı Yaz Yayınları'na aittir, tüm hakları saklıdır. Kitabın tamamı ya da bir kısmı 5846 sayılı Kanun'un hükümlerine göre, kitabı yayınlayan firmanın önceden izni alınmaksızın elektronik, mekanik, fotokopi ya da herhangi bir kayıt sistemiyle çoğaltılamaz, yayınlanamaz, depolanamaz.

E_ISBN 978-625-8678-02-4

Mart 2026 – Afyonkarahisar

Dizgi/Mizanpaj: YAZ Yayınları

Kapak Tasarım: YAZ Yayınları

YAZ Yayınları. Yayıncı Sertifika No: 73086

M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar/AFYONKARAHİSAR

www.yazyayinlari.com

yazyayinlari@gmail.com

İÇİNDEKİLER

Endometrial Patolojiler ve Yapay Zekâ Destekli Tanı Yaklaşımları	1
<i>Erdem GÜRKAN</i>	
Servikal Patolojilerin Yönetiminde Yapay Zekanın Rolü.....	14
<i>Alihan TIĞLI, Yakup BAYKUŞ</i>	
Obstetrik Yoğun Bakımda Yapay Zekâ: Erken Uyarı, Karar Destek ve Güvenli Entegrasyon	46
<i>Kadir KABAHASANOĞLU</i>	
Yapay Zeka Destekli Postpartum Anne-Bebek İzlemi: Ruhsal ve Nörogelişimsel Perspektif.....	72
<i>Merve DİLLİ GÜRKAN</i>	
Obstetrik Ve Jinekolojik Anestezi de Yapay Zekâ: Karar Destek, Prosedürel Yardım, Otomasyon ve Güvenli Entegrasyon	96
<i>Muammer Hayri BEKTAŞ</i>	
Adneksiyel Kitlelerin Yönetimde Yapay Zeka Kullanımı.....	124
<i>Oğuzhan KARAKOÇ</i>	
İn Vitro Fertilizasyon Tedavisinde Yapay Zeka Uygulamaları ve Geleceği	154
<i>Yasemin ERCAN DEĞİRMENCİ, Rulin DENİZ</i>	

"Bu kitapta yer alan bölümlerde kullanılan kaynakların, görüşlerin, bulguların, sonuçların, tablo, şekil, resim ve her türlü içeriğin sorumluluğu yazar veya yazarlarına ait olup ulusal ve uluslararası telif haklarına konu olabilecek mali ve hukuki sorumluluk da yazarlara aittir."

ENDOMETRİAL PATOLOJİLER VE YAPAY ZEKÂ DESTEKLİ TANI YAKLAŞIMLARI

Erdem GÜRKAN¹

1. GİRİŞ

Kadın sağlığının önemli morbidite sebeplerinden biri olan endometrial patolojiler, genellikle anormal uterin kanama ve infertilite sebepleriyle kliniğe başvuran hastalarda tespit edilir. Endometrial patolojilerin tanımlanması klinik değerlendirme, görüntüleme yöntemlerinin ve histopatolojik incelemenin birlikte değerlendirilmesi ile mümkündür.

Son dönemde yapay zekâ destekli sistemler, özellikle görüntünün değerlendirilmesi, tanı yolları, ayırıcı tanı ve histeroskopinin rolü ve dijital patolojide tanısal doğruluğu artırmaktadır. Yapay zekâ teknolojilerine ve bu teknolojilerin tıbbi değerlendirmelere uygulanabilirliğine olan ilgi ve araştırmalar artmaktadır.(Dhombres et al., 2022)

Yapay zekâ destekli sistemler, güçlü görüntüleme sistemleriyle çeşitli tıbbi alanlara girmiş ve tıbbi görüntülerin daha etkili yorumlanması için çok çeşitli yollar ortaya çıkarmıştır.(Gore, 2020; Hosny et al., 2018) Bilgisayar teknolojisiyle yapay zekâ destekli sistemler, tıbbi değerlendirme ve görüntüleme yöntemlerinin ve patolojilerin yorumlanmasını kolaylaştırarak hasta bakımını iyileştirmede insan gücü talebini azaltma potansiyeline sahiptir.(Ahuja, 2019; Liu et al., 2021) Yapay zekâ, büyük veritabanlarını tarayabilmek için girdi eğitim verilerinden otomatik olarak dizayn edilmiş bilgisayar

¹ Op. Dr., Bandırma Eğitim ve Araştırma Hastanesi Kadın Hastalıkları ve Doğum Kliniği, ORCID: 0000-0003-3269-3086.

algoritmalarını kullanır.(Yang & Bang, 2019) Kullanılan algoritmaların modellemeleri sisteme yeni veriler eklendikçe geliştirilebilir.(Waljee & Higgins, 2010) Evrimsel sinir ağları (CNN'ler), birbiriyle ilişkili nöronların bilgiyi işlediği ve ilettiği görsel korteksin yapısını ve organizasyonunu taklit etmeyi hedeflemektedir.(N. Li et al., 2016) Yapay zekâ algoritmaları, görüntü tanıma, işleme, otomatik analiz ve sınıflandırmaya kadar tıbbi görüntüleme alanında da çok önemli bir konuma gelecektir.(Hosny et al., 2018) ve görüntülemelerin büyük oranda kullanıldığı jinekolojide endometrial patolojilerin tespitinde ve değerlendirilmesinde daha etkili kullanılabilir hale geleceği düşünülmektedir.(Drukker et al., 2020)

2. ENDOMETRİAL PATOLOJİLERDE YAPAY ZEKÂ UYGULAMALARI

Postmenapozal dönemde vaginal kanama ile kendisini erken bir evrede gösteren endometrial kanser, gelişmiş ülkelerde en sık görülen jinekolojik malignite olarak yaygınlığı artmaktadır.(Crosbie et al., 2022) Endometrial sitolojinin yanlış negatif sonuç oranının yüksekliği düşünüldüğünde, maliyet-etkinlik açısından yapay zekâ algoritmalarının endometrial kanserin tanısı için histereskopi veya histopatolojik görüntülerin değerlendirilmesinde veya preoperatif MRG tabanlı görüntüleme araçlarının kullanımında çok daha maliyet etkin araçlar olduğu görülmektedir.

Renk-doku incelemesi temelli histereskopi görüntülerinin değerlendirilmesi için bir CAD sistemi geliştiren Neofytou ve arkadaşları, olasılıksal bir sinir ağı (PNN) ve SVM modeli oluşturdular. Bu modellerle normal ve anormal endometrial doku arasında en yüksek doğru sınıflandırma yüzdesine (%79) ulaştılar.(Neofytou et al., 2006)

Endometriyumun histeroskopik görüntülerinin endometrial damarları ve doku özelliklerini inceleyerek sınıflandıran bir sinir ağı Vlachokosta ve arkadaşları tarafından geliştirildi.(Vlachokosta et al., 2013) Çalışma için toplam 77 hasta değerlendirildi. Bunlardan 10'u endometriyal kanserli, 28'i anormal uterin kanamalı ve kontrol grubu olarak patolojisi olmayan 39 hasta değerlendirilmiştir. Burada kullanılan yapay zekâ destekli sinir ağının doğruluğu %91,2 , doğruluğu %93,6 ve özgüllüğü %83,8 olarak tespit edilmiştir.(Vlachokosta et al., 2013)

Zhang ve arkadaşları 2021 yılında yapay zekâ destekli modellerin histeroskopideki rolünü araştırmak için atipi içermeyen endometrial hiperplazi, atipik hiperplazi, endometrial kanser, endometrial polipler ve submukozal myomlar dahil olmak üzere doğrulanmış endometrial lezyonları olan 454 hastadan toplamda 1851 histeroskopik görüntü elde ederek bir model oluşturmuştur.(Zhang, Wang, et al., 2021) Oluşturulan bu model ile endometrial lezyonların değerlendirilmesinde %80,8'lik genel bir doğruluk elde edilmiş ve lezyonların benign veya premalign/malign olarak sınıflandırılması için %90,8 doğruluk, %83,0 duyarlılık, %96,0 özgüllük elde edilmiştir. Bu değerlendirme jinekoloğun değerlendirmesinden daha iyi performans göstermiştir.(Zhang, Wang, et al., 2021)

Bir başka çalışmada ise içerisinde normal bulguların, endometrial poliplerin, endometrial miyomların, atipik endometrial neoplazilerin ve endometrial kanseri içeren 177 videodan elde edilen toplamda 411.800 görüntü ile Xception, MobileNetV2 ve EfficientNetB0 adıyla toplamda 3 model geliştirildi. Bu eğitilmiş modellerin birleştirilmesiyle %90,3 tanısal doğruluk, %91,7 duyarlılık ve %89,4 özgüllük elde edilmiştir.(Takahashi et al., 2021)

Endometriyum kanserinde, tedavi seçimi ve prognozda belirleyici olan myometrial invazyon derinliğinin değerlendirilmesinde yapay zekâ tabanlı MRI analizi, zaman açısından verimli ve maliyet açısından etkili bir yaklaşım olarak görülmektedir.(Chen et al., 2020) Bu çalışmada, patoloji tanısı endometriyum kanseri olduğu doğrulanmış 530 hastadan alınan görüntülerdeki lezyon bölgelerini tespit etmek için YOLOv3 algoritması ile modeli eğitmek ve doğrulamak için kullanıldı ve derin myometrial invazyonun belirlenmesinde %84,8 doğruluk, %66,7 duyarlılık ve %87,5 özgüllük elde edildi.(Chen et al., 2020)

Daha önceki yapay zekâ algoritmalarından daha farklı bir yöntem geliştiren Zhu ve arkadaşları, myometrial invazyon derinliğinin MRG ile değerlendirilmesinde endometriyal kanser tarafından uyarılmış uterus gövdesi içindeki doku yapısının düzensizliğini tanımlamak için dizayn edilmiş bir özellik kullandılar.(Zhu et al., 2021) Sonrasında çok olasılıklı algoritmalar ile doku özelliklerini birleştirerek bir topluluk modeli kurdular ve böylece %93,7 doğruluk, %94,7 duyarlılık ve %93,3 özgüllük elde ederek daha güvenilir sonuçlar oluşturdular. Bu sebeple önerilen yöntemeye dayalı gelecekteki yapay zekâ destekli sınıflandırma, radyologlara MRG’de derin myometrial invazyonu doğru bir şekilde tanımlamada yardımcı olabilir.(Zhu et al., 2021)

Bunlara ek olarak Zhang ve arkadaşları 158 endometriyal kanserli hastanın ameliyat öncesi MR görüntülerini analiz ederek MR’dan elde edilen radyomik özelliklere dayanarak endometriyal kanseri tahmin etmek için bir CNN mimarisi tasarladılar.(Zhang, Gong, et al., 2021) Bu çalışmadan yaklaşık bir yıl sonra endometrial kanseri teşhis etmek için bir CNN modelinin tanısallık performansını üç uzman radyologun sınıflandırmasıyla karşılaştırdılar ve benzer bir performans oluşturdular. (Urushibara et al., 2022)

Endometrial kanser tanısı, histereskopi sırasında elde edilen histopatolojik materyalin değerlendirilmesinden sonra netlik kazanır. Bu anlamda yapay zekânın buradaki gözlemciler arasındaki değişkenlik sorununu azaltacağı düşünülmektedir. Sun ve arkadaşları, histopatolojik endometrial görüntülerin taranması için CNN ve dikkate dayalı CAD yaklaşımı geliştirerek, modelleri ise normal endometriyum, endometrial polip, endometriyal hiperplazi ve endometriyal adenokarsinom olmak üzere dört endometrial doku sınıfı arasında ayırım yapmak üzere tasarladılar.(Sun et al., 2020) Bu algoritma ile çapraz doğrulama veri seti %76,9 doğruluk göstermiş, 200 hematoksilen ve eozin görüntüsünden oluşan doğrulama veri seti ile %84,5 doğruluk elde ettiler. Bu modelin endometrial dokunun morfolojik özellikleriyle olan histopatolojik korelasyonlarını vurgulayarak patolojlara raporlama konusunda ve verileri yorumlamada yardımcı olacağı öngörülmektedir.

Feng ve arkadaşları, yaş , BMI ve 329 endometriyal kanserli hastanın muayene verilerini içeren bir veritabanına dayanarak preoperatif endometrial karsinomun histolojisi, evresini ve derecesini tahmin edebilen bir rastgele orman (RF) modeli üzerinde çalıştılar; bu modelin histoloji tahmini doğruluk oranı %81, hastalık evrelemesi için doğruluk oranı %63 , derecelendirme doğruluk oranı %43 idi.(Feng et al., 2022) Bu sayede doktorların performansından daha yüksek oranlara ulaşılmış olsa da, klinik uygulamaya geçmeden önce iyileştirilmesi önerilmiştir.

Diğer bir çalışmayı Li ve arkadaşları tarafından endometrial kanserli kadınlarda derin myometrial infiltrasyon, klinik risk kategorisi, histolojik tip ve lenfovasküler boşluk invazyonunu tahmin etmede T2 ağırlıklı MR görüntülerinden elde edilen klinik radyomik imzalara dayalı ML sınıflandırma yöntemlerinin performansını değerlendirmeyi amaçlayan çalışmalarını açıkladılar.(X. Li et al., 2023) Derin myometrial

invazyon için AUC 0,79 ,yüksek riskli endometrial kanser için AUC 0,82 , endometrial histolojik tip için AUC 0,91 ve LVSI sınıflandırması için ise AUC 0,85 olması tek bir MRG muayenesi sırasında tanısallık ve prognostik bilgi etmek için ML modeli uygulanmasının yararını göstermektedir.

3. YAPAY ZEKANIN SAĞLADIĞI AVANTAJLAR VE GELECEK PERSPEKTİFİ

Bahsedilen tüm bu çalışmalarda, yapay zekâ daha hızlı ve doğru tahminler ve teşhisler ortaya koyarak yapay zekânın endometrial patolojilerdeki jinekolojik sağlık hizmetlerinin verimliliğini artırmıştır. Bu sistemler, görüntü analizi ve yorumlamasında üstün başarı göstererek çok güçlü araçlar ortaya koymuştur. Doktorların yerini alacağından çok, aksine klinik uygulamaya mükemmel uyum sağlayarak artan iş yükü ve yorgunluk nedeniyle oluşabilecek hataları ve gözlemciler arası değişkenliği azaltacağı öngörülmektedir. Daha iyi ve daha hızlı analiz yapabilme, daha güvenilir sonuçlar ortaya çıkarabilme ve de sonuç olarak hastanın sağkalımını artırabilme yeteneği en önemli özelliğini oluşturacaktır.(Murphy et al., 2021)

Yapay zekanın geriye dönük veri değerlendirmesi kullanılarak seçim yanlılığı veya spektrum yanlılığı düşünülerek günlük uygulama öncesinde dikkatlice test edilmelidir. Yapay zekâ araçları, yeni veriler oluşukça ve algoritmalarla beslendikçe sınıflandırma performansları iyileşecektir. Büyük veri çağının gelişi yakın gelecekte yapay zekâ tekniklerinin gelişimini hızlandıracaktır.(Murphy et al., 2021)

Yapay zekâ modellerinin geliştirilmesinde, teknolojinin geliştirildiği popülasyona uygulanamayabileceği doğal bir spektrum yanlılığı vardır. Bu çalışmaların birçoğunda yerel veya ulusal hasta veri setinde oluşturuldukları için potansiyel bir spektrum yanlılığı bulunmaktadır. Bu yanlılığı aşmak için

sonuçların heterojen çok merkezli bir bağlamda senaryoda doğrulanmasının gerekliliği göz önüne alınmıştır.(Mascarenhas et al., 2023)

Modelin güvenilirliği açısından açıklanabilir olması için ML veya DL modelinin verilen çıktıyı gerekçelendirebilmesi gerekir. Bu açıklanabilir yapay zekânın önemine dair birçok çalışma yapılmıştır.(Belle & Papantonis, 2021; Linardatos et al., 2020)

Yapay zekâ endeksli kararlarda yasal sorumluluğun üç faktöre bölünmesi önerilmiş: modelin tasarımı, insan-makine etkileşimi ve yapay zekâ endeksli insan kararı.(Bleher & Braun, 2022) Bununla birlikte, şu anda sağlık hizmetlerinde yapay zekâ kullanımıyla ilgili etik ve yasal konulara ilişkin iyi tanımlanmış düzenlemeler bulunmamaktadır; fakat bunun yapay zekâ ile ilgili etkili uygulamaların standartlaştırılması için öncelikli olmalıdır.(Naik et al., 2022)

4. SONUÇ

Endometrial patolojiler, geniş klinik spektrumu ve malignite potansiyeli nedeniyle erken ve doğru tanı gerektiren önemli bir sağlık sorunudur. Günümüz klinik değerlendirme, görüntüleme yöntemleri ve histopatolojik inceleme birlikte kullanılarak yüksek tanısal doğruluk sağlanabilmektedir. Ayrıca, özellikle premalign ve malign lezyonların ayırımında gözlemciye bağlı değişkenlik ve yöntemsel sınırlılıklar devam etmektedir. Bu noktada yapay zekâ ve özellikle derin öğrenme tabanlı yaklaşımlar, hem görüntüleme hem de dijital patoloji alanında daha objektif, tekrarlanabilir ve yüksek doğruluklu değerlendirmeler sunarak tanı süreçlerini güçlendirmektedir. Histeroskopi gibi ileri tanı yöntemleri ile yapay zekâ uygulamalarının entegrasyonu, hedefe yönelik biyopsi, erken tanı ve bireyselleştirilmiş hasta yönetimi açısından önemli fırsatlar

sunmaktadır. Ancak bu teknolojilerin rutin klinik pratiğe güvenli ve etkin şekilde entegre edilmesi için geniş ölçekli prospektif çalışmalar, standart veri setleri ve etik çerçevelerin geliştirilmesi gerekmektedir.

Sonuç olarak, endometrial patolojilerin tanısında en ideal yaklaşım; klinik deneyim ile yapay zekâ destekli analitik sistemlerin birlikte kullanıldığı, multidisipliner ve entegre bir modeldir. Bu yaklaşımın, gelecekte jinekolojik onkolojide tanısal doğruluğu artırarak hasta sonuçlarının anlamlı ölçüde iyileşmesi beklenmektedir.

KAYNAKÇA

- Ahuja, A. S. (2019). The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ*, 7, e7702. <https://doi.org/10.7717/peerj.7702>
- Belle, V., & Papantonis, I. (2021). Principles and Practice of Explainable Machine Learning. *Frontiers in Big Data*, 4. <https://doi.org/10.3389/fdata.2021.688969>
- Bleher, H., & Braun, M. (2022). Diffused responsibility: attributions of responsibility in the use of AI-driven clinical decision support systems. *AI and Ethics*, 2(4), 747–761. <https://doi.org/10.1007/s43681-022-00135-x>
- Chen, X., Wang, Y., Shen, M., Yang, B., Zhou, Q., Yi, Y., Liu, W., Zhang, G., Yang, G., & Zhang, H. (2020). Deep learning for the determination of myometrial invasion depth and automatic lesion identification in endometrial cancer MR imaging: a preliminary study in a single institution. *European Radiology*, 30(9), 4985–4994. <https://doi.org/10.1007/s00330-020-06870-1>
- Crosbie, E. J., Kitson, S. J., McAlpine, J. N., Mukhopadhyay, A., Powell, M. E., & Singh, N. (2022). Endometrial cancer. *The Lancet*, 399(10333), 1412–1428. [https://doi.org/10.1016/S0140-6736\(22\)00323-3](https://doi.org/10.1016/S0140-6736(22)00323-3)
- Dhombres, F., Bonnard, J., Bailly, K., Maurice, P., Papageorgiou, A. T., & Jouannic, J.-M. (2022). Contributions of Artificial Intelligence Reported in Obstetrics and Gynecology Journals: Systematic Review. *Journal of Medical Internet Research*, 24(4), e35465. <https://doi.org/10.2196/35465>
- Drukker, L., Noble, J. A., & Papageorgiou, A. T. (2020). Introduction to artificial intelligence in ultrasound imaging in obstetrics and gynecology. *Ultrasound in*

- Obstetrics & Gynecology*, 56(4), 498–505.
<https://doi.org/10.1002/uog.22122>
- Feng, Y., Wang, Z., Xiao, M., Li, J., Su, Y., Delvoux, B., Zhang, Z., Dekker, A., Xanthoulea, S., Zhang, Z., Traverso, A., Romano, A., Zhang, Z., Liu, C., Gao, H., Wang, S., & Qian, L. (2022). An Applicable Machine Learning Model Based on Preoperative Examinations Predicts Histology, Stage, and Grade for Endometrial Cancer. *Frontiers in Oncology*, 12. <https://doi.org/10.3389/fonc.2022.904597>
- Gore, J. C. (2020). Artificial intelligence in medical imaging. *Magnetic Resonance Imaging*, 68, A1–A4.
<https://doi.org/10.1016/j.mri.2019.12.006>
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. W. L. (2018). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500–510.
<https://doi.org/10.1038/s41568-018-0016-5>
- Li, N., Zhao, X., Yang, Y., & Zou, X. (2016). Objects Classification by Learning-Based Visual Saliency Model and Convolutional Neural Network. *Computational Intelligence and Neuroscience*, 2016, 1–12.
<https://doi.org/10.1155/2016/7942501>
- Li, X., Dessi, M., Marcus, D., Russell, J., Aboagye, E. O., Ellis, L. B., Sheeka, A., Park, W.-H. E., Bharwani, N., Ghaem-Maghami, S., & Rockall, A. G. (2023). Prediction of Deep Myometrial Infiltration, Clinical Risk Category, Histological Type, and Lymphovascular Space Invasion in Women with Endometrial Cancer Based on Clinical and T2-Weighted MRI Radiomic Features. *Cancers*, 15(8), 2209. <https://doi.org/10.3390/cancers15082209>
- Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2020). Explainable AI: A Review of Machine Learning

- Interpretability Methods. *Entropy*, 23(1), 18. <https://doi.org/10.3390/e23010018>
- Liu, P., Lu, L., Zhang, J., Huo, T., Liu, S., & Ye, Z. (2021). Application of Artificial Intelligence in Medicine: An Overview. *Current Medical Science*, 41(6), 1105–1115. <https://doi.org/10.1007/s11596-021-2474-3>
- Mascarenhas, M., Afonso, J., Ribeiro, T., Andrade, P., Cardoso, H., & Macedo, G. (2023). The Promise of Artificial Intelligence in Digestive Healthcare and the Bioethics Challenges It Presents. *Medicina*, 59(4), 790. <https://doi.org/10.3390/medicina59040790>
- Murphy, K., Di Ruggiero, E., Upshur, R., Willison, D. J., Malhotra, N., Cai, J. C., Malhotra, N., Lui, V., & Gibson, J. (2021). Artificial intelligence for good health: a scoping review of the ethics literature. *BMC Medical Ethics*, 22(1), 14. <https://doi.org/10.1186/s12910-021-00577-8>
- Naik, N., Hameed, B. M. Z., Shetty, D. K., Swain, D., Shah, M., Paul, R., Aggarwal, K., Ibrahim, S., Patil, V., Smriti, K., Shetty, S., Rai, B. P., Chlosta, P., & Somani, B. K. (2022). Legal and Ethical Consideration in Artificial Intelligence in Healthcare: Who Takes Responsibility? *Frontiers in Surgery*, 9. <https://doi.org/10.3389/fsurg.2022.862322>
- Neofytou, M. S., Pattichis, M. S., Pattichis, C. S., Tanos, V., Kyriacou, E. C., & Koutsouris, D. D. (2006). Texture-Based Classification of Hysteroscopy Images of the Endometrium. *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, 3005–3008. <https://doi.org/10.1109/IEMBS.2006.259811>

- Sun, H., Zeng, X., Xu, T., Peng, G., & Ma, Y. (2020). Computer-Aided Diagnosis in Histopathological Images of the Endometrium Using a Convolutional Neural Network and Attention Mechanisms. *IEEE Journal of Biomedical and Health Informatics*, 24(6), 1664–1676. <https://doi.org/10.1109/JBHI.2019.2944977>
- Takahashi, Y., Sone, K., Noda, K., Yoshida, K., Toyohara, Y., Kato, K., Inoue, F., Kukita, A., Taguchi, A., Nishida, H., Miyamoto, Y., Tanikawa, M., Tsuruga, T., Iriyama, T., Nagasaka, K., Matsumoto, Y., Hirota, Y., Hiraike-Wada, O., Oda, K., ... Fujii, T. (2021). Automated system for diagnosing endometrial cancer by adopting deep-learning technology in hysteroscopy. *PLOS ONE*, 16(3), e0248526. <https://doi.org/10.1371/journal.pone.0248526>
- Urushibara, A., Saida, T., Mori, K., Ishiguro, T., Inoue, K., Masumoto, T., Satoh, T., & Nakajima, T. (2022). The efficacy of deep learning models in the diagnosis of endometrial cancer using MRI: a comparison with radiologists. *BMC Medical Imaging*, 22(1), 80. <https://doi.org/10.1186/s12880-022-00808-3>
- Vlachokosta, A. A., Asvestas, P. A., Gkrozou, F., Lavasidis, L., Matsopoulos, G. K., & Paschopoulos, M. (2013). Classification of hysteroscopic images using texture and vessel descriptors. *Medical & Biological Engineering & Computing*, 51(8), 859–867. <https://doi.org/10.1007/s11517-013-1058-1>
- Waljee, A. K., & Higgins, P. D. R. (2010). Machine Learning in Medicine: A Primer for Physicians. *American Journal of Gastroenterology*, 105(6), 1224–1226. <https://doi.org/10.1038/ajg.2010.173>
- Yang, Y. J., & Bang, C. S. (2019). Application of artificial intelligence in gastroenterology. *World Journal of*

Gastroenterology, 25(14), 1666–1683.
<https://doi.org/10.3748/wjg.v25.i14.1666>

Zhang, Y., Gong, C., Zheng, L., Li, X., & Yang, X. (2021). Deep Learning for Intelligent Recognition and Prediction of Endometrial Cancer. *Journal of Healthcare Engineering*, 2021, 1–8. <https://doi.org/10.1155/2021/1148309>

Zhang, Y., Wang, Z., Zhang, J., Wang, C., Wang, Y., Chen, H., Shan, L., Huo, J., Gu, J., & Ma, X. (2021). Deep learning model for classifying endometrial lesions. *Journal of Translational Medicine*, 19(1), 10. <https://doi.org/10.1186/s12967-020-02660-x>

Zhu, X., Ying, J., Yang, H., Fu, L., Li, B., & Jiang, B. (2021). Detection of deep myometrial invasion in endometrial cancer MR imaging based on multi-feature fusion and probabilistic support vector machine ensemble. *Computers in Biology and Medicine*, 134, 104487. <https://doi.org/10.1016/j.compbiomed.2021.104487>

SERVİKAL PATOLOJİLERİN YÖNETİMİNDE YAPAY ZEKANIN ROLÜ

Alihan TIĞLI¹

Yakup BAYKUŞ²

1. GİRİŞ

Servikal patolojiler, kadınlarda ciddi morbidite ve mortaliteye neden olabilen belign enflamatuar hastalıklar, premalign lezyonlar ve invaziv servikal kansere kadar geniş bir spektrumdaki tüm hastalıkları kapsar(Zampaoglou et al., 2025). Özellikle Servikal intraepitelyal neoplazi (CIN) ve adenokarsinoma in situ (AIS) gibi premalign lezyonların erken ve doğru tespiti bu lezyonların invaziv servikal kansere ilerlemesini önlemek için kritik öneme sahiptir(Hristamyan, 2025; Katabathina et al., 2024). Serviks kanseri, dünya çapında kadınları etkileyen en yaygın malignitelerden biri olmaya devam etmekte ve özellikle düşük ve orta gelirli ülkelerde önemli bir halk sağlığı sorunu oluşturmaktadır(Özbilgeç et al., 2025). Etkili tarama stratejileri ve doğru klinik yönetim yaklaşımları, bu küresel yükü mücadele etmek için çok önemlidir(Aleezada, Patel, & Yusuf, 2025).

Servikal lezyonları tespit etmek için kullanılan geleneksel yöntemler servikal sitoloji (Pap smear), insan papilloma virüsü (HPV) testi ve kolposkopi bulunmaktadır(Whitlock et al., 2011). HPV enfeksiyonu, başta serviks kanseri olmak üzere anal, penis,

¹ Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Kadın Hastalıkları ve Doğum Anabilim, ORCID: 0000-0002-9404-4869.

² Prof. Dr, Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Kadın Hastalıkları ve Doğum Anabilim, ORCID: 0000-0001-5730-8477.

vulva, vajina ve orofaringeal maligniteler gibi birçok kanserin başlıca nedenidir(Schiffman et al., 2011). Yüksek riskli HPV (HR-HPV) tarama testi, HPV taraması için güvenilir bir yöntemdir ve CIN gibi premalign lezyonların tespiti ile invazif serviks kanserine dönüşümü öncesinde erken teşhisini için oldukça faydalıdır(Huh et al., 2015). Örneğin, HPV tip 16, HPV negatif bireylere kıyasla %22 oranında bir olasılık oranı ile CIN II ve üzeri lezyonlarının önemli bir bağımsız belirleyicisi olarak tanımlanmıştır. Bu nedenle özellikle HPV 16 – 18 pozitif kadınlar, erken tanı ve invaziv kanser ilerlemenin önüne geçilmesi için yakından izlenmeli ve zamanında kolposkopik değerlendirilmelidir(Özbilgeç et al., 2025). Kolposkopi, önemli bir tanı yöntemidir ve doğruluğu, tarama ve takip testlerine dayalı olarak serviks kanseri premalign lezyonları tespit etme konusunda yapılan meta-analizler ve incelemelere göre de oldukça güvenilirdir(*Cervical cancer screening*, 2022).

Uzun süredir kullanılmalarına rağmen, geleneksel tarama yöntemlerinin, özellikle gözlemciye bağlı değişkenlik, yorumlama zorlukları ve zaman ve maliyet yükü gibi sınırlamaları vardır. Bu sınırlamalar, gözlemciler arası ve gözlemciler içi farklılıkların tanı doğruluğunu etkileyebileceği sitolojik değerlendirmelerde daha belirgindir(*Screening for Cervical Cancer: A Systematic Evidence Review for the U.S. Preventive Services Task Force*, 2011). Bu sınırlamaları gidermek için, HPV genotipleme, p16/ki67 ekspresyonu ve HPV mRNA testi gibi risk sınıflandırmasında gelişmeler ortaya çıkmıştır. Bu gelişmeler, tanı doğruluğunu artırabilir ve serviks neoplazmalarının tanımlanmasına yardımcı olabilir(Gori et al., 2025). Özellikle HPV mRNA testi, serviks kanserini tespit etmede yüksek hassasiyet ve özgüllük gösterdiği ve mevcut tarama yöntemlerini tamamlayabileceği veya bunlara alternatif olabileceği düşünülmektedir(Arbyn et al., 2022).

Geleneksel ve yeni yöntemlere ek olarak günümüzde yapay zeka (AI), makine öğrenmesi ve derin öğrenme algoritmaları sayesinde sağlık alanında tanı, tedavi ve klinik karar destek süreçlerinde önemli bir dönüşüm sağlamıştır(Hou et al., 2022). Bu algoritmalar, büyük veri setlerini analiz etme, karmaşık örüntüleri tanımlama ve insan gözünden kaçabilecek detayları saptama potansiyeline sahiptir. Özellikle görüntü analizi gerektiren alanlarda, AI destekli sistemlerin performansı dikkate değer seviyelere ulaşmıştır(Hamashima, 2021).

Bu gelişmeler, AI'nın servikal sitoloji, HPV ile ilişkili risk değerlendirmesi ve kolposkopik görüntü analizi gibi kritik alanlarda kullanımını ön plana çıkarmıştır. Bazı çalışmalar derin öğrenme modelleri servikal kanser taraması ve triyajında sitopatologların hassasiyetini arttırdığını ve okuma sürelerini önemli ölçüde azalttığını göstermektedir(Xue et al., 2025). Geliştirilen bazı yazılımlar, Tele-servikografi görüntülerinde yüksek riskli lezyonlar için %98 hassasiyet ve %95,5 özgüllük göstermiştir(Ouh et al., 2024). AI destekli sistemlerin, kolposkopik değerlendirmelerde tanısal değişkenliği azaltarak klinik karar verme süreçlerini desteklediği bildirilmektedir(Aquilina & Papagiannakis, 2024).

Bu bölümünün amacı, servikal patolojilerin tanı ve yönetiminde AI uygulamalarının güncel durumunu ortaya koymak, klinik pratiğe olan katkılarını ve sınırlılıklarını değerlendirmek ve gelecekteki potansiyel kullanım alanlarını tartışmaktır. Bu kapsamda, servikal patolojilerde kullanılan geleneksel yöntemler ile AI temelli yaklaşımlar karşılaştırılacak; AI'nın klinik karar süreçlerindeki yeri ele alınacaktır.

2. SERVİKAL PATOLOJİLER: TEMEL KAVRAMLAR VE KLİNİK YÖNETİM

Servikal patolojiler, etiyoloji, klinik seyir ve malignite potansiyeli açısından geniş bir spektrum göstermektedir. Bu patolojilerin doğru sınıflandırılması, uygun tanı yöntemlerinin seçilmesi ve etkili klinik yönetim stratejilerinin belirlenmesi açısından büyük önem taşımaktadır. Güncel yaklaşımlar, servikal patolojilerin yalnızca histopatolojik özelliklerine değil, aynı zamanda HPV ilişkisi, hastanın yaşı, immün durumu ve üreme planları gibi bireysel faktörlere dayalı olarak değerlendirilmesini önermektedir.

2.1. Servikal Patolojilerin Sınıflandırılması

Servikal patolojiler genel olarak benign, premalign ve malign lezyonlar olmak üzere üç ana grupta ele alınmaktadır.

Benign servikal lezyonlar çoğunlukla inflamatuvar veya reaktif süreçler nedeniyle gelişir. Servisit, ektopi, Naboth kistleri ve polipler bu gruptaki en sık gözlenen lezyonlardır. Bu lezyonlar genellikle asemptomatiktir ve malign transformasyon riski oldukça düşüktür. Ancak, sitolojik incelemelerde premalign değişikliklerle karıştırılabilecek hücresel bulgulara yol açabileceğinden, dikkatli bir değerlendirme gerektirirler(European Centre for Disease Prevention and Control, 2024).

Premalign servikal lezyonlar ise CIN ve AIS dur. CIN, skuamöz epiteldeki displastik değişikliklerin derecesine göre CIN I, CIN II ve CIN III olarak sınıflandırılır. CIN I lezyonları genellikle spontan regresyon gösterebilir. Ancak CIN II ve CIN III lezyonları yüksek dereceli olarak kabul edilir ve invaziv kansere ilerleme riski taşır. AIS, glandüler epitelden kaynaklanan premalign bir lezyondur ve CIN 3 ile birlikte, invaziv servikal kanserden hemen önce gelen ve erken tanı ve dikkatli tedavi gerektiren bir patolojik durum olarak kabul edilir(European

Centre for Disease Prevention and Control, 2024). Malign servikal patolojiler arasında invaziv servikal kanserlerden skuamöz hücreli karsinom ve adenokarsinom yer alır(European Centre for Disease Prevention and Control, 2024). Bu lezyonlar genellikle, servikal kanserlerin önemli bir kısmının nedeni olan uzun süreli ve kalıcı HR-HPV enfeksiyonlarının bir sonucu olarak gelişir(Jensen, Becker, Jackson, & Rysavy, 2024). Tanı anındaki hastalığın evresi, prognozu ve tedavi seçeneklerini belirleyen en önemli faktördür(Wu et al., 2025).

2.2. Güncel Tanı ve Yönetim Yaklaşımları

Güncel klinik uygulamalar Amerikan Kolposkopi ve Servikal Patoloji Derneği (ASCCP), Avrupa Jinekolojik Onkoloji Derneği (ESGO) ve Uluslararası Jinekoloji ve Obstetrik Federasyonu (FIGO) gibi uluslararası rehberler doğrultusunda şekillenmektedir. Bu rehberler, risk temelli yaklaşımları ön plana çıkararak hastaların bireysel özelliklerine göre izlem ve tedavi stratejilerinin belirlenmesini önermektedir. Özellikle ASCCP'nin risk bazlı algoritmaları, yalnızca mevcut test sonuçlarını değil, hastanın önceki tarama öyküsünü de dikkate alarak daha kişiselleştirilmiş bir yönetim modeli sunmaktadır.

Servikal patolojilerin tanı ve tedavisinde, tarama, tanı ve tedavi süreçlerinin birbirini tamamlayan adımlar olduğu kabul edilen çok aşamalı, entegre bir yaklaşım benimsenmektedir. Servikal sitoloji, Pap smear ve sıvı bazlı sitoloji gibi yöntemlerin kullanımı servikal taramanın temelini oluşturur(Terasawa et al., 2022). Sitolojik inceleme, erken aşamada hücresel atipi tespitini mümkün kılarak, premalign lezyonların tanımlanmasını kolaylaştırır(Wentzensen et al., 2024). Sıvı bazlı sitoloji, örnek kalitesini iyileştirdiği, HPV ve moleküler analizler gibi ek testleri mümkün kıldığı için günümüzde giderek daha fazla kullanılmaktadır(Fontham et al., 2020). Ancak sitolojik

değerlendirme, yorumlamadaki doğal değişkenlik nedeniyle standardizasyona da ihtiyaç duyulmaktadır.

HPV testleri, özellikle HR-HPV tiplerinin saptanmasında yüksek duyarlılığa sahiptir ve şu anda birçok ülkede birincil tarama yöntemi olarak önerilmektedir(Thrall, McCarthy, Mito, & Rao, 2025). HPV temelli tarama, büyük uluslararası çalışmalarda serviks kanseri öncüsü lezyonların saptanmasında ve kanser insidansının azaltılmasında sitoloji taramasına göre daha üstün olduğu belirtilmektedir(Wentzensen et al., 2024). Ayrıca HPV genotipleme, klinik karar verme süreçlerinde, kalıcı enfeksiyonun değerlendirilmesinde ve ilerleyici lezyon riskinin tahmin edilmesinde de önemli bir rol oynar(Kyrgiou et al., 2020).

Kolposkopi anormal sitoloji veya pozitif HPV test sonuçlarının ardından tanıyı doğrulamak için altın standart yöntemler olarak kabul edilir. Kolposkopik değerlendirme, servikal epiteldeki anormal alanların görsel olarak tanımlanmasına ve hedefe yönelik biyopsi örnekleme yapılmasına olanak tanır(Wentzensen et al., 2024). Bununla birlikte, kolposkopinin deneyime bağlı doğası ve gözlemci farklılıkları tanı doğruluğunu etkileyebilir. Mevcut klinik uygulama ASCCP, ESGO ve Avrupa Kolposkopi Federasyonu (EFC) gibi kuruluşların uluslararası kılavuzları tarafından şekillendirilmektedir(Fontham et al., 2020; Kyrgiou et al., 2020; Zampaoglou et al., 2025). Bu kılavuzlar risk temelli yaklaşımlara öncelik vermekte ve takip ve tedavi stratejilerinin her hastanın bireysel özelliklerine göre belirlenmesini önermektedir. Özellikle, ASCCP'nin risk temelli algoritmaları, mevcut test sonuçlarını ve hastanın önceki tarama geçmişini dikkate alarak daha kişiselleştirilmiş bir yönetim modeli sunmaktadır.

3. SERVİKAL SİTOLOJİDE YAPAY ZEKA UYGULAMALARI

Servikal sitoloji, servikal kanser taramasının temel bileşenlerinden biri olup uzun yıllardır Pap smear ve sıvı bazlı sitoloji yöntemleriyle uygulanmaktadır. Ancak sitolojik değerlendirme, hücresel morfolojinin yorumlanmasına dayandığı için gözlemciye bağlı değişkenlik içermekte ve bu durum tanısal doğruluğu etkileyebilmektedir. Son yıllarda AI tabanlı sistemler, bu sınırlılıkları azaltmak ve sitolojik değerlendirmeleri daha objektif hale getirmek amacıyla geliştirilmiştir.

3.1. Pap Smear ve Sıvı Bazlı Sitolojide Yapay Zeka

AI uygulamaları hem geleneksel Pap smear preparatlarının hem de sıvı bazlı sitoloji örneklerinin analizinde giderek daha fazla kullanılmakta ve serviks kanseri taramasında devrim niteliğinde yenilikler vadetmektedir(Harinath et al., 2025). Derin öğrenme tabanlı algoritmalar, yüksek çözünürlüklü dijital sitoloji görüntülerini analiz ederek hücresel anormallikleri tespit edebilir ve genellikle emek yoğun ve hataya açık olan geleneksel manuel değerlendirmeye kıyasla tanı doğruluğunu ve verimliliğini önemli ölçüde artırır(William, Ware, Basaza-Ejiri, & Obungoloch, 2018). Sıvı bazlı sitoloji örnekleri, otomatik analiz için tüm slayt görüntülerine dijitalleştirilebilen daha homojen hücresel dağılımları nedeniyle AI modellerini eğitmek için belirgin bir avantaj sunar(Kanavati et al., 2022). Bu AI sistemleri, normal ve anormal hücreleri etkili bir şekilde ayırt ederek güçlü ön tarama araçları olarak işlev görür. Çalışmalar, AI destekli modların tanı performansını önemli ölçüde artırdığını, servikal sitopatoloji tanısında sensitivite ve spesiviteyi önemli ölçüde artırdığını preparatların okunma süresini de önemli ölçüde azalttığını göstermektedir(Xue et al., 2025). AI'nın bu entegrasyonu, serviks neoplazisinin erken teşhisini geliştirerek ve özellikle kaynakların sınırlı olduğu ortamlarda daha verimli ve

doğru tarama uygulamalarını destekler(Habtemariam, Zewde, & Simegn, 2022).

AI destekli sitoloji sistemleri, çekirdek boyutu, çekirdek-sitoplazma oranı, kromatin yapısı ve hücresel düzensizlikler dahil olmak üzere hücrelerin önemli morfolojik özelliklerini otomatik olarak analiz edebilir(Sood, Khandnor, & Bhatia, 2024). Gelişmiş derin öğrenme algoritmalarından yararlanarak, bu sistemler hem geleneksel Pap smear hem de sıvı bazlı sitoloji örneklerinden elde edilen yüksek çözünürlüklü dijital sitoloji görüntülerinden binlerce hücreyi hızla değerlendirebilir(Shinde, Kalbhor, & Wajire, 2022). Bu özellik, potansiyel olarak gözden kaçan anormal hücrelerin tespit edilmesine önemli ölçüde yardımcı olarak serviks kanseri taramasının genel doğruluğunu artırır.

3.2. ASC-US, LSIL ve HSIL Ayırımında Yapay Zeka

Atipik skuamöz hücreleri (ASC-US) düşük dereceli (LSIL) ve yüksek dereceli skuamöz intraepitelyal lezyonlardan (HSIL) ayırt etmek, sitolojik tanıda önemli bir zorluk teşkil etmektedir(Sornapudi et al., 2020). AI tabanlı modeller, bu lezyonlar arasındaki ince morfolojik farklılıkları öğrenerek sınıflandırma doğruluğunu artırır(Takahashi et al., 2022). Algoritmalar, özellikle HSIL gibi kritik lezyonlar için yüksek hassasiyet gösterir ve erken tanı ve uygun hasta yönetimine katkıda bulunur. Derin öğrenme modelleri, HSIL tespiti için %91'in üzerinde doğruluk ve skuamöz intraepitelyal lezyonlar (SIL) için 0,935 AUC değerine ulaşmıştır(Wang et al., 2024). AI destekli sistemler, ASC-US, LSIL ve HSIL için tanı hassasiyetini %20,2'ye kadar ve özgüllüğü %22,3'e kadar artırılabilir(Z. Ye et al., 2025).

AI destekli sitoloji sistemlerinin performansı genellikle duyarlılık ve özgüllük parametreleri kullanılarak değerlendirilir. Araştırmalar, AI algoritmalarının yüksek dereceli skuamöz intraepitelyal lezyonları (HSIL) tespit etmede yüksek duyarlılık

sağladığını tutarlı bir şekilde göstermektedir(Wang et al., 2024). Ancak, spesifiklik, belirli önemi olmayan atipik skuamöz hücreler (ASC-US) ve düşük dereceli skuamöz intraepitelyal lezyonlar (LSIL) gibi düşük dereceli lezyonlar için değişiklik gösterebilir(Z. C. Ye et al., 2025). Bu değişkenlik, AI'nın bağımsız bir tanı aracı olarak değil, destekleyici bir sistem olarak entegre edilmesinin önemini vurgulamakta ve sitopatologların tanı güvenilirliğini ve performansını artırmalarına yardımcı olmaktadır(Z. Ye et al., 2025).

Güncel yaklaşımlar, serviks sitolojisinde patoloğların veya sitopatologların yerini AI'nın alması yerine, insan uzmanlığını yapay zeka ile birleştiren hibrit modelleri vurgulamaktadır(Vaccaro, Almaatouq, & Malone, 2024). Bu iş birliğine dayalı modellerde, AI şüpheli alanları işaretleyerek veya ön sınıflandırmalar yaparak uzman değerlendirmesini destekler(Andreassen, Mortensen, Stenbro, Sørensen, & Sørbye, 2025). Bu tür insan-AI hibrit sistemleri, tanısal doğruluğu kanıtlanabilir şekilde artırarak duyarlılığı ve özgüllüğü önemli ölçüde geliştirmiştir(Takahashi et al., 2025). Ayrıca, yanlış negatif oranlarını azaltır ve klinik karar verme süreçlerini güçlendirir(Civit-Masot, Luna-Perejon, Muñoz-Saavedra, Domínguez-Morales, & Civit, 2024). Bu iş birliğine dayalı yaklaşım, AI'nın servikal sitolojide etkili bir şekilde klinik olarak entegre edilmesi için en gerçekçi ve uygulanabilir model olarak kabul edilmektedir(Giansanti et al., 2025).

4. HPV TESTLERİ VE RİSK STRATİFİKASYONUNDA YAPAY ZEKA

HPV enfeksiyonu, serviks premalign ve malign lezyonlarının gelişiminde birincil etiyolojik faktör olarak yaygın olarak kabul edilmektedir. HPV 16 ve HPV 18 gibi yüksek riskli tipler, özellikle serviks kanserinin oluşumu ve prognozunda rol

oynamaktadır(Lei et al., 2022). Ancak, çoğu HPV enfeksiyonu geçicidir ve klinik olarak önemli lezyonlara ilerlemez. Bu nedenle, doğru klinik yönetim sadece HPV pozitifliğini tespit etmekle kalmayıp, enfeksiyonun kalıcılığını ve ilerleme riskini de kesin olarak değerlendirmekle yakından ilgilidir(Andralojc et al., 2022). AI tabanlı yaklaşımlar, bu karmaşık risk değerlendirme sürecine önemli katkılar sağlar(El-Zein et al., 2023).

4.1. HPV Genotipleme ve Yapay Zeka

HPV Genotiplenmesi HR-HPV tiplerinin tanımlanmasını sağlayarak serviks kanseri riskinin daha doğru bir şekilde sınıflandırılmasını kolaylaştırır(Demarco et al., 2020). Yapay zeka algoritmaları, çeşitli HPV genotipleri ile sitolojik ve klinik sonuçlar arasındaki ilişkiyi analiz ederek risk düzeylerini daha ayrıntılı bir şekilde belirleyebilir(Shi et al., 2025). Özellikle HPV 16 ve HPV 18 gibi yüksek onkogenik potansiyele sahip genotiplerin varlığında, yapay zeka destekli modeller, daha yakından izlenmesi gereken hasta alt gruplarını belirlemede etkilidir. Sitoloji ile birlikte bir triyaj stratejisi olarak genotipleme, yüksek dereceli serviks lezyonlarının tespitini iyileştirebilir(El-Zein et al., 2023). Persiste HPV enfeksiyonu, CIN ve invaziv kanser gelişimi için en önemli risk faktörlerinden biridir(Andralojc et al., 2022). AI sistemleri, tekrarlanan HPV test sonuçlarını, zaman içindeki genotip değişikliklerini ve eşlik eden sitolojik bulguları birlikte değerlendirerek kalıcı enfeksiyonları daha doğru bir şekilde tespit edebilir(Abrar, Isa, Hairon, Ismail, & Kadir, 2025). Bu bütünsel yaklaşım, tek bir test sonucuna dayalı değerlendirmelerin ötesine geçerek kapsamlı uzunlamasına veri analizine olanak tanır. Deep HPV gibi derin öğrenme modelleri, risk değerlendirmesi için çok önemli olan insan genomundaki HPV entegrasyon bölgelerini bile tahmin edebilir(Tian et al., 2021).

4.2. Progresyon Riskinin Tahmini ve Klinik Karar Destek Sistemleri

AI tabanlı risk modelleri, HPV genotipi, enfeksiyon süresi, sitolojik bulgular ve hasta özelliklerini birleştirerek premalign lezyonların ilerleme olasılığını tahmininde umut vaatetmektedir(Farzaneh, Soltani, Dastyar, Mohammadi, & Hosseini, 2025). Bu modeller, klinisyenlerin hangi hastaların daha agresif izleme veya erken müdahale gerektirdiğini belirlemesine yardımcı olabilir. Çalışmalar, makine öğrenimi (ML) modellerinin yüksek tanı doğruluğu sağlayabildiğini göstermiştir. Bir ML modeli, serviks kanseri riskini tahmin etmek için %95,6 doğruluk ve 0,958 AUROC değeri bildirmiştir(Toffaha, Simsekler, Sleptchenko, Kortt, & Bukasa, 2025). AI destekli risk tahmin sistemleri, özellikle düşük dereceli lezyonlarda gereksiz müdahaleleri önleme ve yüksek riskli hastaları erken teşhis etme konusunda önemli avantajlar sunar(Abrar et al., 2025).

HPV testi ve yapay zekanın entegrasyonu, sofistike klinik karar destek sistemlerinin geliştirilmesinin önünü açmaktadır(Pawar, Pingale, Kadam, Jadhav, & Kaul-Ghanekar, 2025). Bu sistemler, hastaya özgü birçok değişkeni aynı anda analiz eder ve klinisyenlere önerilerde bulunur. Mevcut kılavuzlara uygun olarak çalışan AI tabanlı karar destek sistemleri, kolposkopi endikasyonları, takip sıklığı ve tedavi gereksinimleri gibi alanlarda daha standart ve kişiselleştirilmiş bir yönetim yaklaşımı sağlamayı amaçlamaktadır(Toffaha et al., 2025). Bu modellerin kullanımı hasta güvenliğinin artırılması ve özellikle uzman personel sayısının az olduğu kaynakları kısıtlı ortamlarda sağlık kaynaklarının daha verimli kullanılmasını sağlayacaktır(Yang et al., 2024). Yapay zeka araçları, parçalı tıbbi verileri etkili bir şekilde eyleme geçirilebilir bilgilere dönüştürerek hasta sonuçlarının iyileştirilmesine katkıda bulunabilir.

5. KOLPOSKOPİ VE GÖRÜNTÜ ANALİZİNDE YAPAY ZEKA

Kolposkopi, serviks patolojilerinin teşhisinde sitoloji ve HPV testlerini tamamlayan temel bir değerlendirme yöntemidir. Ancak kolposkopik muayene, büyük ölçüde klinisyenin deneyimine ve öznel yorumuna dayanmaktadır(Aquilina & Papagiannakis, 2024). Gözlemciye bağlı bu değişkenlik, lezyonların gözden kaçması veya yanlış yorumlanması gibi sorunlara yol açabilir ve bu da standardizasyon ve iyileştirme ihtiyacını vurgular(Harris, Lavin, Akin, Papagiannakis, & Denardis, 2020). Dijital görüntüleme teknolojilerindeki gelişmeler ve AI algoritmalarının bu alana entegrasyonu, kolposkopik değerlendirmenin standartlaştırılmasını ve daha objektif hale getirilmesini mümkün kılmaktadır(Thomas et al., 2025).

5.1. Dijital Kolposkopi ve Görüntü Tabanlı Yapay Zeka Algoritmaları

Dijital kolposkopi sistemleri, serviksin yüksek çözünürlüklü görüntülerinin elde edilmesini ve bu görüntülerin arşivlenmesini ve analizini sağlar(Jeronimo, Massad, Castle, Wacholder, & Schiffman, 2007). Geleneksel kolposkopiye kıyasla, bu sistemler görüntü kalitesini iyileştirir ve uzaktan değerlendirme ve teletıp gibi yeni uygulamaların önünü açar(Poudel et al., 2024). Yapay zeka algoritmaları kullanarak dijital görüntüleri analiz etme yeteneği, kolposkopinin tanı yeteneklerini daha da geliştirerek daha iyi tanı performansı sağlar(Phiri et al., 2026).

Yapay zeka tabanlı görüntü analiz sistemleri, kolposkopik görüntülerdeki vasküler paternler, epitel yüzey özellikleri ve asetobeyaz alanlar gibi morfolojik bulguları otomatik olarak değerlendirebilir(Thomas et al., 2025). Özellikle evrimsel sinir ağlarına (CNN) dayalı modeller, lezyonları iyi huylu veya

prealign olarak sınıflandırabilir(Jeronimo et al., 2007). Bu algoritmalar, insan gözünün ayırt etmesi zor olan ince morfolojik farklılıkları tespit ederek tanısal doğruluğu artırmayı amaçlamaktadır(Poudel et al., 2024). AI'nın, görüntüleme verilerini kullanarak HPV varlığını tahmin etmede %79'luk bir duyarlılık ve %74'lük bir özgüllük elde ettiği gösterilmiştir, bu da umut verici bir performans olduğunu göstermektedir(Song et al., 2023).

5.2. Lezyon Lokalizasyonu ve Biyopsi Yönlendirme

Kolposkopide doğru biyopsi bölgesini seçmek, tanının başarısını belirleyen en önemli faktörlerden biridir. Yapay zeka destekli sistemler, kolposkopik görüntülerde şüpheli bölgeleri işaretleyerek klinisyenlere biyopsi alınması gereken bölgeleri gösterir. Bu yaklaşım, özellikle multifokal veya kötü tanımlanmış lezyonlarda hedefe yönelik biyopsiye katkıda bulunur, böylece tanı verimliliğini artırır ve gereksiz biyopsileri önleyebilir(Xue et al., 2020). Yapay zeka modelleri ayrıca serviksndaki belirleyici noktaları tanımlayabilir ve lezyonları lokalize edebilir(McDonald-Bowyer et al., 2025).

AI destekli kolposkopi sistemlerinin klinik doğruluğu, çeşitli çalışmalarda umut verici sonuçlar göstermiştir(Talathi, Dabhadkar, Doke, & Singh, 2025). Yüksek dereceli lezyonları tespit etmede duyarlılığın arttığı ve gözlemciler arası varyasyonun azaldığı, bu da tanı güvenilirliğini ve uzmanlar arasındaki uyumu artırdığı görülmektedir. Çalışmalar, AI sistemlerinin servikal sitopatoloji için duyarlılık ve özgüllük açısından desteksiz modlardan daha iyi performans gösterdiğini göstermiştir(Z. Ye et al., 2025). Hatta bazı çalışmalarda, patolojik yüksek dereceli skuamöz intraepitelyal lezyon veya daha kötüsünü (HSIL+) tespit etmede kolposkopistlerden daha yüksek duyarlılık gösterirken, benzer özgüllükleri koruduğu görülmüştür(Xue et al., 2020). Ancak, bu sistemlerin

performansı, kullanılan veri setlerinin kalitesine, hasta popülasyonuna ve algoritma eğitim sürecine bağlı olarak değişebilir. AI, kaynakların sınırlı olduğu ortamlarda bile sağlam bir performans sunsa da, standartlaştırılmış veri setlerine duyulan ihtiyaç, çeşitli popülasyonlarda geçerlilik ve veri gizliliği ve teknolojiye erişimle ilgili etik hususlar gibi zorluklar devam etmektedir(Ahmed et al., 2024). Gerçek klinik ortamlarda yaygın olarak kullanılmadan önce, büyük ölçekli, prospektif doğrulama çalışmaları gereklidir. AI destekli kolposkopi, mevcut klinik uygulamaların yerine geçmekten ziyade, klinisyenlere karar desteği sağlayan tamamlayıcı bir araç olarak düşünülmelidir(Xue et al., 2025). Bu yaklaşım, servikal patolojilerin tanı ve yönetimi için daha güvenilir ve standartlaştırılmış bir klinik sürecin oluşturulmasına katkıda bulunabilir.

6. SERVİKAL PATOLOJİLERİN YÖNETİMİNDE YAPAY ZEKA DESTEKLİ KARAR SİSTEMLERİ

Servikal patolojilerin yönetimi, tarama sonuçlarının yorumlanması, tedavi kararları ve takip planlamasını kapsayan çok sayıda klinik değişkenin kapsamlı bir değerlendirmesini gerektirir. Bu karmaşık, çok boyutlu sürecin objektifliğini, standardizasyonunu ve kişiselleştirilmesini geliştirmek için AI destekli karar sistemleri geliştirilmektedir(Chen et al., 2025). Güncel AI uygulamaları, tek bir tanı yöntemine bağlı kalmanın ötesine geçerek, çeşitli veri kaynaklarını entegre ederek bütünsel yaklaşımlar sunmaktadır(Pawar et al., 2025).

6.1. Tanıdan Tedaviye Yapay Zeka Entegrasyonu

AI destekli sistemler, servikal sitoloji, HPV test sonuçları, kolposkopik görüntüler ve hasta klinik bilgileri dahil olmak üzere çeşitli tanı girdilerini eşzamanlı olarak analiz etme yeteneğine sahiptir(Civit-Masot et al., 2024). Bu entegre analitik kapasite, ilk

tarama ve kolposkopi endikasyonundan biyopsi kararlarına, tedavi seçimine ve sonraki takip planlamasına kadar tüm klinik süreci kapsayabilir(Wentzensen et al., 2024). Birden fazla kaynaktan gelen verileri sentezleyerek, klinisyenler tek bir test sonucuna dayalı kararların ötesine geçerek daha kapsamlı değerlendirmeler yapabilirler(Wang et al., 2024). Örneğin, derin öğrenme modelleri serviks sitopatoloji tanısında gelişmiş duyarlılık göstermiş ve kanser öncesi ve kanser tespiti için sıvı bazlı sitolojide başarıyla uygulanmıştır(Shinde et al., 2022). AI araçları, yüksek riskli popülasyonlar ve düşük kaynaklı ülkeler dahil olmak üzere çeşitli ortamlarda serviks kanseri öncesi taramada etkinlikleri açısından da değerlendirilmektedir(Phiri et al., 2026).

6.2. Hasta Bazlı Risk Skorlarının Oluşturulması

AI tabanlı modeller, geniş bir yelpazede hasta özel verilerinden yararlanarak kişiselleştirilmiş risk skorları oluşturabilir. Bu risk skorları genellikle HPV genotipi, enfeksiyon süresi, sitolojik ve histopatolojik bulgular, hasta yaşı ve önceki tarama sonuçları gibi çok sayıda değişkeni içerir 7 17. Bu hasta merkezli risk değerlendirmesi, yüksek riskli bireylerin erken teşhisini kolaylaştırarak daha yoğun izleme veya zamanında müdahale stratejilerinin geliştirilmesini sağlar(Farzaneh et al., 2025) 4. Çalışmalar, kritik HPV alt tiplerinin tespitini iyileştirmek ve taramanın doğruluğunu artırmak amacıyla, AI kullanarak CIN için prognostik tahmin destek sistemleri geliştirmeye odaklanmıştır(Takahashi et al., 2022). AI destekli öngörüselleştirme, CIN şiddetini değerlendirmede, kişiselleştirilmiş tarama stratejilerini desteklemede ve gereksiz invaziv prosedürleri azaltmada güçlü bir performans sergilemiştir(Farzaneh et al., 2025).

6.3. Aşırı Tedavi ve Yetersiz Tedavinin Azaltılması

Servikal patolojilerin yönetiminde önemli bir zorluk, düşük riskli hastalar için gereksiz müdahalelerin (aşırı tedavi) ve yüksek riskli bireyler için yetersiz izleme veya gecikmiş tedavinin (yetersiz tedavi) ortaya çıkmasıdır 4. AI destekli karar sistemleri, daha hassas risk sınıflandırması sağlayarak her iki aşırılığın da önemli ölçüde azaltabilir 4. Bu sistemler, özellikle düşük dereceli lezyonlar için gereksiz cerrahi müdahaleleri önlemek ve yüksek dereceli lezyonlar için hızlı tedavi sağlamak açısından önemli klinik avantajlar sunar 16 4. AI, geleneksel yöntemlere kıyasla yüksek dereceli skuamöz intraepitelyal lezyonları (HSIL) tanımlamada üstün performans göstermiştir ve bu da daha uygun klinik eylemlerin gerçekleştirilmesine rehberlik edebilir(Mascarenhas et al., 2025).

6.4. Klinik İş Akışına Entegrasyon

AI tabanlı karar destek sistemlerinin klinik uygulamada başarılı bir şekilde kullanılması, mevcut iş akışlarına sorunsuz bir şekilde entegre edilmesine bağlıdır. Bu sistemlerin kullanıcı dostu arayüzlere sahip olması, yerleşik klinik kılavuzlarla uyumlu öneriler sunması ve klinisyenlerin karar verme sürecini hızlandırması çok önemlidir. Derin öğrenme destekli sistemlerin, özellikle eşzamanlı okuma modlarında, sitopatologların okuma süresini önemli ölçüde azalttığı ve tanı güvenilirliğini artırdığı gösterilmiştir. Etkili klinik entegrasyon, AI'yı otonom bir "karar verici" olarak değil, klinisyenin uzmanlığını artıran destekleyici bir araç olarak konumlandırır ve böylece daha fazla benimsenmesini ve klinik kullanışlılığını teşvik eder(Valles-Coral et al., 2026). AI, tanı desteği ve doğruluk açısından önemli bir potansiyel sergilese de, yaygın uygulama için standardizasyon, sınırlı klinik doğrulama ve altyapı maliyetleri gibi zorlukların hala ele alınması gerekmektedir(Zhang, Yuan, & Chen, 2026).

7. AVANTAJLAR, SINIRLILIKLAR VE ETİK BOYUT

AI uygulamaları, servikal patolojilerin tanı ve yönetiminde önemli fırsatlar sunmakla birlikte, klinik kullanıma entegrasyon sürecinde çeşitli sınırlılıklar ve etik sorumlulukları da beraberinde getirmektedir. Bu nedenle AI'nın potansiyel katkılarının ve kısıtlılıklarının dengeli bir bakış açısıyla değerlendirilmesi gerekmektedir. AI tabanlı sistemlerin en önemli avantajlarından biri, klinik değerlendirmelerde standartlaşmayı desteklemesidir. Sitoloji, HPV testleri ve kolposkopi gibi alanlarda gözlemciye bağlı değişkenliğin azaltılması, tanısal tutarlılığın artmasına katkı sağlamaktadır. Bu durum, özellikle farklı merkezler arasında uygulama farklılıklarının bulunduğu sağlık sistemlerinde önemli bir kazanım olarak değerlendirilmektedir. Bir diğer önemli avantaj, zaman ve maliyet etkinliğidir. AI destekli ön tarama ve sınıflandırma sistemleri, yoğun iş yükü altındaki laboratuvarlarda değerlendirme süresini kısaltabilmekte ve insan kaynağının daha verimli kullanılmasına olanak tanımaktadır. Uzun vadede bu sistemlerin, gereksiz tetkik ve müdahalelerin azaltılmasına katkı sağlayarak sağlık harcamalarını düşürmesi beklenmektedir.

Bu avantajların yanında belirli YZ kullanımında bazı sınırlılıklar da mevcuttur. AI sistemlerinin performansı, büyük ölçüde veri kalitesine bağlıdır. Eğitilen veri setlerinin yetersiz, hatalı veya homojen olmaması, algoritmaların klinik gerçekliği doğru yansıtamamasına neden olabilmektedir. Özellikle farklı popülasyonları temsil etmeyen veri setleri, klinik genellenebilirliği sınırlandırabilir. Bir diğer önemli sorun, bias (önyargı) riskidir. AI algoritmaları, eğitildikleri verilerde mevcut olan önyargıları öğrenerek bu hataları pekiştirebilir. Bu durum, belirli hasta gruplarında tanısal hatalara veya eşitsizliklere yol açabilir. Ayrıca, birçok AI uygulaması için klinik validasyon eksikliği önemli bir sınırlılık oluşturmaktadır. Laboratuvar veya

pilot çalışmalar umut verici sonuçlar sunsa da, gerçek yaşam koşullarında ve farklı merkezlerde yapılan prospektif çalışmalar sınırlıdır. Bu nedenle, AI sistemlerinin rutin klinik kullanıma girmeden önce kapsamlı validasyon süreçlerinden geçmesi gerekmektedir.

Klinik sınırlılıklarla birlikte halen çözülmemiş etik ve hukuksal sınırlılıklarda mevcuttur. Tanısal bir hatanın oluşması durumunda sorumluluğun klinisyene mi, yazılım geliştiricisine mi ait olduğu konusu henüz net bir çerçeveye oturmamıştır. Ayrıca hasta verilerinin gizliliği ve güvenliği, AI uygulamalarında özel bir hassasiyet gerektirmektedir. Büyük veri setleriyle çalışan sistemlerde, kişisel sağlık verilerinin korunması ve etik kurallara uygun kullanımı temel bir gerekliliktir. Ayrıca, klinisyenlerin AI önerilerini sorgulayabilmesi ve bu önerilerin şeffaf biçimde açıklanabilir olması, güvenilir klinik kullanım açısından büyük önem taşımaktadır. Bu belirsizlik, AI sistemlerinin karar destek aracı olarak konumlandırılmasının önemini ortaya koymaktadır.

8. GELECEK PERSPEKTİFLER

AI teknolojilerindeki hızlı gelişmeler, servikal patolojilerin tanı ve yönetiminde gelecekte daha bütüncül ve kişiselleştirilmiş yaklaşımların önünü açmaktadır. Mevcut uygulamalar ağırlıklı olarak tanı destek sistemlerine odaklanmış olsa da, önümüzdeki dönemde AI'nın koruyucu hekimlikten tedavi planlamasına kadar uzanan daha geniş bir klinik yelpazede etkin rol oynaması beklenmektedir.

HPV aşı programları, servikal kanser insidansının azaltılmasında en etkili halk sağlığı girişimlerinden biridir. Gelecekte AI destekli sistemlerin, aşılama verileri ile tarama sonuçlarını entegre ederek toplum bazlı risk haritaları oluşturması mümkün olabilir. Bu yaklaşım, aşılanmış ve aşılanmamış

popülasyonlarda tarama sıklıklarının ve yöntemlerinin daha rasyonel şekilde planlanmasına katkı sağlayabilir.

Dijital kolposkopi ve tele-tıp uygulamalarının yaygınlaşması, AI destekli telekolposkopi sistemlerinin gelişimini hızlandırmaktadır. Uzaktan görüntü aktarımı ve AI tabanlı ön değerlendirme sistemleri, özellikle uzman erişiminin sınırlı olduğu bölgelerde tanı süreçlerini iyileştirebilir. Bu modeller, erken tanı olanaklarını artırarak sağlık hizmetlerine erişimdeki eşitsizliklerin azaltılmasına katkı sağlayacaktır.

Gelecekte servikal kanser tarama programlarının, tek tip algoritmalar yerine kişiselleştirilmiş risk temelli stratejilere yönelmesi beklenmektedir. AI, bireysel hasta özelliklerini, HPV genotiplerini, önceki tarama sonuçlarını ve klinik verileri bir arada değerlendirerek kişiye özgü tarama aralıkları ve yöntemleri önerebilir. Bu yaklaşım hem klinik etkinliği artırabilir hem de gereksiz tarama ve müdahalelerin önüne geçebilir.

AI'nın büyük veri analizi ve genetik bilgilerle entegrasyonu, servikal patolojilerin yönetiminde yeni bir dönemi başlatma potansiyeline sahiptir. Genetik yatkınlıklar, immün yanıt profilleri ve moleküler belirteçlerin AI algoritmalarıyla birlikte değerlendirilmesi, hastalık progresyonunun daha doğru öngörülmesini sağlayabilir. Bu bütüncül yaklaşım, gelecekte daha hassas ve bireyselleştirilmiş klinik kararların temelini oluşturabilir.

9. SONUÇ

AI uygulamaları, servikal patolojilerin tanı ve yönetiminde klinik pratiğe önemli katkılar sunma potansiyeline sahiptir. Servikal sitoloji, HPV testleri ve kolposkopi gibi geleneksel yöntemlerin AI destekli sistemlerle birlikte kullanılması, tanısal doğruluğun artırılmasına, gözlemciye bağlı

değişkenliğin azaltılmasına ve klinik karar süreçlerinin daha standart hale getirilmesine olanak sağlamaktadır. Bu yaklaşımlar, özellikle erken tanı ve uygun hasta yönetimi açısından klinik fayda sunmaktadır.

AI'nın servikal patolojilerin yönetimindeki rolü, hekim kararlarının yerini almaktan ziyade, klinisyene destek sağlayan tamamlayıcı bir araç olarak değerlendirilmelidir. İnsan ve AI iş birliğine dayalı modeller, mevcut klinik uygulamaların güçlendirilmesine katkı sağlamakta ve daha güvenilir bir tanı-tedavi sürecinin oluşturulmasını mümkün kılmaktadır.

Bununla birlikte, AI uygulamalarının rutin klinik kullanıma entegrasyonu için geniş ölçekli, prospektif ve çok merkezli çalışmalara ihtiyaç bulunmaktadır. Klinik validasyon, etik ve hukuki çerçevenin netleştirilmesi ve farklı popülasyonlarda genellenebilirliğin değerlendirilmesi, gelecekteki araştırmaların öncelikli alanları arasında yer almalıdır. Bu doğrultuda, AI teknolojilerinin bilinçli ve kontrollü şekilde klinik pratiğe entegre edilmesi, servikal patolojilerin yönetiminde daha etkin ve sürdürülebilir bir sağlık hizmeti sunumuna katkı sağlayacaktır.

KAYNAKLAR

- Abrar, S. S., Isa, S. A. M., Hairon, S. M., Ismail, M. P., & Kadir, M. N. B. N. A. (2025). Recent advances in applications of machine learning in cervical cancer research: a focus on prediction models. *Obstetrics & Gynecology Science*, 68(4), 247–259. doi:10.5468/ogs.25041
- Ahmed, S. R., Egemen, D., Befano, B., Rodriguez, A. C., Jeronimo, J., Desai, K., ... Schiffman, M. (2024). Assessing generalizability of an AI-based visual test for cervical cancer screening. *PLOS Digital Health*, 3(10), e0000364. doi:10.1371/journal.pdig.0000364
- Aleezada, Z. N., Patel, I., & Yusuf, N. (2025). Understanding HPV-Induced Cancers and Investigating the Barriers Faced by Low- and Middle-Income Countries in Prevention and Treatment. *International Journal of Molecular Sciences*, 26(12), 5581. doi:10.3390/ijms26125581
- Andralojc, K. M., Elmelik, D., Rasing, M., Pater, B., Siebers, A. G., Bekkers, R., ... Leenders, W. P. J. (2022). Targeted RNA next generation sequencing analysis of cervical smears can predict the presence of hrHPV-induced cervical lesions. *BMC Medicine*, 20(1), 206. doi:10.1186/s12916-022-02386-1
- Andreassen, A. K., Mortensen, E., Stenbro, R., Sørensen, Ø., & Sørbye, S. W. (2025). Digital Pathology with AI for Cervical Biopsies: Diagnostic Accuracy at the CIN2+ Threshold. *Cancers*, 17(23), 3808. doi:10.3390/cancers17233808
- Aquilina, A., & Papagiannakis, E. (2024). Deep Learning Diagnostic Classification of Cervical Images to Augment Colposcopic Impression. *Journal of Lower Genital Tract*

Disease, 28(3), 224–230.
doi:10.1097/LGT.0000000000000815

Arbyn, M., Simon, M., de Sanjosé, S., Clarke, M. A., Poljak, M., Rezhake, R., ... Wentzensen, N. (2022). Accuracy and effectiveness of HPV mRNA testing in cervical cancer screening: a systematic review and meta-analysis. *The Lancet. Oncology*, 23(7), 950–960. doi:10.1016/S1470-2045(22)00294-7

Cervical cancer screening. (2022). International Agency for Research on Cancer.

Chen, M., Ma, J., Wu, Y., Hu, H., Cui, X., Gonzalez Mendez, M. J., ... Qiao, Y. (2025). Accelerating the elimination of global cervical cancer through intelligent training for colposcopy. *Cancer Biology & Medicine*, 1036–1052. doi:10.20892/j.issn.2095-3941.2025.0403

Civit-Masot, J., Luna-Perejon, F., Muñoz-Saavedra, L., Domínguez-Morales, M., & Civit, A. (2024). A lightweight xAI approach to cervical cancer classification. *Medical & Biological Engineering & Computing*, 62(8), 2281–2304. doi:10.1007/s11517-024-03063-6

Demarco, M., Egemen, D., Raine-Bennett, T. R., Cheung, L. C., Befano, B., Poitras, N. E., ... Schiffman, M. (2020). A Study of Partial Human Papillomavirus Genotyping in Support of the 2019 ASCCP Risk-Based Management Consensus Guidelines. *Journal of Lower Genital Tract Disease*, 24(2), 144–147. doi:10.1097/LGT.0000000000000530

El-Zein, M., Bouten, S., Abdrabo, L. S., Siblini, A., Louvanto, K., Franco, E., & Ferenczy, A. (2023). Genotyping and Cytology Triage of High-Risk HPV DNA Positive

- Women for Detection of Cervical High-Grade Lesions. *Journal of Lower Genital Tract Disease*, 27(1), 12–18. doi:10.1097/LGT.0000000000000706
- European Centre for Disease Prevention and Control. (2024). Efficacy, effectiveness and safety of HPV vaccination in women with conisation: a systematic review and meta-analyses. *Stockholm: ECDC*. doi:10.2900/315115
- Farzaneh, F., Soltani, A., Dastyar, F., Mohammadi, M., & Hosseini, M. S. (2025). AI-Driven predictive modeling of cervical intraepithelial neoplasia severity: a comprehensive analysis with clinical adoption frameworks. *BMC Cancer*, 25(1), 1521. doi:10.1186/s12885-025-14974-4
- Fontham, E. T. H., Wolf, A. M. D., Church, T. R., Etzioni, R., Flowers, C. R., Herzig, A., ... Smith, R. A. (2020). Cervical cancer screening for individuals at average risk: 2020 guideline update from the American Cancer Society. *CA: A Cancer Journal for Clinicians*, 70(5), 321–346. doi:10.3322/caac.21628
- Giansanti, D., Lastrucci, A., Pirrera, A., Villani, S., Carico, E., & Giarnieri, E. (2025). AI in Cervical Cancer Cytology Diagnostics: A Narrative Review of Cutting-Edge Studies. *Bioengineering (Basel, Switzerland)*, 12(7). doi:10.3390/bioengineering12070769
- Gori, S., Venturelli, F., Carozzi, F., Giorgi Rossi, P., Del Mistro, A., Maggino, T., ... Preti, E. P. (2025). Italian guidelines for cervical cancer screening. Multisocietal recommendations on the use of biomarkers in HPV screening with risk-based approach and GRADE methodology. *British Journal of Cancer*, 133(8), 1076–1084. doi:10.1038/s41416-025-03161-8

- Habtemariam, L. W., Zewde, E. T., & Simegn, G. L. (2022). Cervix Type and Cervical Cancer Classification System Using Deep Learning Techniques. *Medical Devices: Evidence and Research*, Volume 15, 163–176. doi:10.2147/MDER.S366303
- Hamashima, C. (2021). Emerging technologies for cervical cancer screening. *Japanese Journal of Clinical Oncology*, 51(9), 1462–1470. doi:10.1093/jjco/hyab109
- Harinath, L., Bai, X., Minkowitz, J., Zeng, X., Harrington, S., Zhao, C., & Pantanowitz, L. (2025). Artificial Intelligence in Gynecologic Cytology. *Acta Cytologica*, 70(1), 52–71. doi:10.1159/000546182
- Harris, K., Lavin, P., Akin, M., Papagiannakis, E., & Denardis, S. (2020). Rate of detecting CIN3+ among patients with ASC-US using digital colposcopy and dynamic spectral imaging. *Oncology Letters*. doi:10.3892/ol.2020.11878
- Hou, X., Shen, G., Zhou, L., Li, Y., Wang, T., & Ma, X. (2022). Artificial Intelligence in Cervical Cancer Screening and Diagnosis. *Frontiers in Oncology*, 12. doi:10.3389/fonc.2022.851367
- Hristamyan, M. A. (2025). Primary and Secondary Prophylaxis for Diseases Caused by Human Papillomavirus Infections. *Journal of Cancer Prevention*, 30(3), 146–153. doi:10.15430/JCP.25.018
- Huh, W. K., Ault, K. A., Chelmow, D., Davey, D. D., Goulart, R. A., Garcia, F. A. R., ... Einstein, M. H. (2015). Use of Primary High-Risk Human Papillomavirus Testing for Cervical Cancer Screening. *Obstetrics & Gynecology*, 125(2), 330–337. doi:10.1097/AOG.0000000000000669

- Jensen, J. E., Becker, G. L., Jackson, J. B., & Rysavy, M. B. (2024). Human Papillomavirus and Associated Cancers: A Review. *Viruses*, 16(5), 680. doi:10.3390/v16050680
- Jeronimo, J., Massad, L. S., Castle, P. E., Wacholder, S., & Schiffman, M. (2007). Interobserver Agreement in the Evaluation of Digitized Cervical Images. *Obstetrics & Gynecology*, 110(4), 833–840. doi:10.1097/01.AOG.0000281665.63550.8f
- Kanavati, F., Hirose, N., Ishii, T., Fukuda, A., Ichihara, S., & Tsuneki, M. (2022). A Deep Learning Model for Cervical Cancer Screening on Liquid-Based Cytology Specimens in Whole Slide Images. *Cancers*, 14(5), 1159. doi:10.3390/cancers14051159
- Katabathina, V. S., Ghannam, S., Chen, M., Desalme, B., Gabos, R., Emejulu, I., ... Prasad, S. R. (2024). Update on Pathologic Conditions, Imaging Findings, Prevention, and Management of Human Papillomavirus-related Neoplasms. *RadioGraphics*, 44(8). doi:10.1148/rg.230179
- Kyrgiou, M., Arbyn, M., Bergeron, C., Bosch, F. X., Dillner, J., Jit, M., ... Gultekin, M. (2020). Cervical screening: ESGO-EFC position paper of the European Society of Gynaecologic Oncology (ESGO) and the European Federation of Colposcopy (EFC). *British Journal of Cancer*, 123(4), 510–517. doi:10.1038/s41416-020-0920-9
- Lei, J., Arroyo-Mühr, L. S., Lagheden, C., Eklund, C., Nordqvist Kleppe, S., Elfström, M., ... Sundström, K. (2022). Human Papillomavirus Infection Determines Prognosis in Cervical Cancer. *Journal of Clinical Oncology*, 40(14), 1522–1528. doi:10.1200/JCO.21.01930

- Mascarenhas, M., Martins, M., Barroso, L., Spindler, L., Fathallah, N., Manzione, T., ... de Parades, V. (2025). Automated detection and classification of cervical and anal squamous cancer precursors using deep learning and multidevice colposcopy. *Scientific Reports*, 15(1), 33068. doi:10.1038/s41598-025-14514-x
- McDonald-Bowyer, A., Wijekoon, A., Love, R. L., Allan, K., Colvin, S., Gentry-Maharaj, A., ... Bano, S. (2025). Automated Cervical Os Segmentation for Camera-Guided, Speculum-Free Screening.
- Ouh, Y.-T., Kim, T. J., Ju, W., Kim, S. W., Jeon, S., Kim, S.-N., ... Lee, J.-K. (2024). Development and validation of artificial intelligence-based analysis software to support screening system of cervical intraepithelial neoplasia. *Scientific Reports*, 14(1), 1957. doi:10.1038/s41598-024-51880-4
- Özbilgeç, S., Akkuş, F., Şener, R., Dönmez, E. E., Serin, E. C., & Acar, A. (2025). HPV status and colposcopy: key predictors in cervical cancer and precancerous lesion diagnosis. *Northwestern Medical Journal*, 5(4), 201–208. doi:10.54307/2025.NWMJ.162
- Pawar, M., Pingale, S., Kadam, K., Jadhav, A., & Kaul-Ghanekar, R. (2025). Artificial intelligence-driven screening, early diagnosis, and treatment strategies for cervical cancer: an overview. *Infectious Agents and Cancer*, 21(1), 1. doi:10.1186/s13027-025-00716-5
- Phiri, H., Uwinkindi, F., Diop, M., Mwanahamuntu, M., Gondongwe, L., Guzha, B. T., ... Parham, G. (2026). Performance of an artificial intelligence-based tool for cervical precancer screening in five countries in Africa: a prospective, observational, diagnostic accuracy study.

The Lancet Global Health, 14(1), e49–e60.
doi:10.1016/S2214-109X(25)00352-3

Poudel, K., Poudel, L., Shakya, P. R., Poudel, A., Shrestha, A., & Khanal, B. (2024). AI-Assisted Cervical Cancer Screening.

Schiffman, M., Wentzensen, N., Wacholder, S., Kinney, W., Gage, J. C., & Castle, P. E. (2011). Human Papillomavirus Testing in the Prevention of Cervical Cancer. *JNCI: Journal of the National Cancer Institute*, 103(5), 368–383. doi:10.1093/jnci/djq562

Screening for Cervical Cancer: A Systematic Evidence Review for the U.S. Preventive Services Task Force. (2011).

Shi, L., Chen, H., Zhang, Z., Wang, Y., Ren, W., & Huang, J. (2025). Evolving HPV diagnostics: current practice and future frontiers. *Frontiers in Cellular and Infection Microbiology*, 15. doi:10.3389/fcimb.2025.1681779

Shinde, S., Kalbhor, M., & Wajire, P. (2022). DeepCyto: a hybrid framework for cervical cancer classification by using deep feature fusion of cytology images. *Mathematical Biosciences and Engineering*, 19(7), 6415–6434. doi:10.3934/mbe.2022301

Song, C., Chen, X., Tang, C., Xue, P., Jiang, Y., & Qiao, Y. (2023). Artificial intelligence for HPV status prediction based on disease-specific images in head and neck cancer: A systematic review and meta-analysis. *Journal of Medical Virology*, 95(9). doi:10.1002/jmv.29080

Sood, T., Khandnor, P., & Bhatia, R. (2024). Enhancing pap smear image classification: integrating transfer learning and attention mechanisms for improved detection of cervical abnormalities. *Biomedical Physics & Engineering Express*, 10(6), 065031. doi:10.1088/2057-1976/ad7bc0

- Sornapudi, S., Stanley, R. J., Stoecker, W. V., Long, R., Xue, Z., Zuna, R., ... Antani, S. (2020). DeepCIN: Attention-Based Cervical histology Image Classification with Sequential Feature Modeling for Pathologist-Level Accuracy. *Journal of Pathology Informatics*, 11(1), 40. doi:10.4103/jpi.jpi_50_20
- Takahashi, T., Kobayashi, Y., Sakurai, R., Matsuoka, K., Akatsuka, J., Kisu, I., ... Tamiya, G. (2025). A Systematic Review of the Application of Artificial Intelligence in Colposcopy: Diagnostic Accuracy for Cervical Intraepithelial Neoplasia and Cervical Cancer. *Clinical Medicine Insights: Oncology*, 19. doi:10.1177/11795549251374908
- Takahashi, T., Matsuoka, H., Sakurai, R., Akatsuka, J., Kobayashi, Y., Nakamura, M., ... Tamiya, G. (2022). Development of a prognostic prediction support system for cervical intraepithelial neoplasia using artificial intelligence-based diagnosis. *Journal of Gynecologic Oncology*, 33(5). doi:10.3802/jgo.2022.33.e57
- Talathi, M. A., Dabhadkar, S., Doke, P. P., & Singh, V. (2025). Accuracy of the AI-Based Smart Scope® Test as a Point-of-Care Screening and Triage Tool Compared to Colposcopy: A Pilot Study. *Cureus*. doi:10.7759/cureus.81212
- Terasawa, T., Hosono, S., Sasaki, S., Hoshi, K., Hamashima, Y., Katayama, T., & Hamashima, C. (2022). Comparative accuracy of cervical cancer screening strategies in healthy asymptomatic women: a systematic review and network meta-analysis. *Scientific Reports*, 12(1), 94. doi:10.1038/s41598-021-04201-y
- Thomas, A., Brar, S., Weitoshova, A., Yerra, S., Gutierrez, C., & Vinagolu-Baur, J. (2025). Artificial Intelligence

- Enhanced Colposcopy Supports Early Detection of High Grade Cervical Intraepithelial Neoplasia in HPV Positive Individuals. *International Journal of Research Studies in Microbiology and Biotechnology*, 10(1), 28–35. doi:10.20431/2454-9428.1001005
- Thrall, M. J., McCarthy, E., Mito, J. K., & Rao, J. (2025). Triage options for positive high-risk HPV results from HPV-based cervical cancer screening: a review of the potential alternatives to Papanicolaou test cytology. *Journal of the American Society of Cytopathology*, 14(1), 11–22. doi:10.1016/j.jasc.2024.09.003
- Tian, R., Zhou, P., Li, M., Tan, J., Cui, Z., Xu, W., ... Hu, Z. (2021). DeepHPV: a deep learning model to predict human papillomavirus integration sites. *Briefings in Bioinformatics*, 22(4). doi:10.1093/bib/bbaa242
- Toffaha, K., Simsekler, M. C. E., Sleptchenko, A., Kortt, M., & Bukasa, L. (2025). A Machine Learning and Bayesian Belief Network Approach to Predicting Cervical Cancer Risk: Implications for Risk Management. *Journal of Multidisciplinary Healthcare, Volume 18*, 5199–5211. doi:10.2147/JMDH.S524132
- Vaccaro, M., Almaatouq, A., & Malone, T. (2024). When combinations of humans and AI are useful: A systematic review and meta-analysis. *Nature Human Behaviour*, 8(12), 2293–2303. doi:10.1038/s41562-024-02024-1
- Valles-Coral, M. A., Pinedo, L., Rodríguez, C., Rodríguez, D., Sánchez-Dávila, K., Arévalo-Fasanando, L., & Reátegui-Lozano, N. (2026). Application of artificial intelligence in cervical cytology: a systematic review of deep learning models, datasets, and reported metrics. *Frontiers in Big Data*, 8. doi:10.3389/fdata.2025.1678863

- Wang, J., Yu, Y., Tan, Y., Wan, H., Zheng, N., He, Z., ... Yao, H. (2024). Artificial intelligence enables precision diagnosis of cervical cytology grades and cervical cancer. *Nature Communications*, 15(1), 4369. doi:10.1038/s41467-024-48705-3
- Wentzensen, N., Garcia, F., Clarke, M. A., Massad, L. S., Cheung, L. C., Egemen, D., ... Perkins, R. B. (2024). Enduring Consensus Guidelines for Cervical Cancer Screening and Management: Introduction to the Scope and Process. *Journal of Lower Genital Tract Disease*, 28(2), 117–123. doi:10.1097/LGT.0000000000000804
- Whitlock, E. P., Vesco, K. K., Eder, M., Lin, J. S., Senger, C. A., & Burda, B. U. (2011). Liquid-Based Cytology and Human Papillomavirus Testing to Screen for Cervical Cancer: A Systematic Review for the U.S. Preventive Services Task Force. *Annals of Internal Medicine*, 155(10), 687–697. doi:10.7326/0003-4819-155-10-201111150-00376
- William, W., Ware, A., Basaza-Ejiri, A. H., & Obungoloch, J. (2018). A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images. *Computer Methods and Programs in Biomedicine*, 164, 15–22. doi:10.1016/j.cmpb.2018.05.034
- Wu, J., Jin, Q., Zhang, Y., Ji, Y., Li, J., Liu, X., ... Huang, Y. (2025). Global burden of cervical cancer: current estimates, temporal trend and future projections based on the GLOBOCAN 2022. *Journal of the National Cancer Center*, 5(3), 322–329. doi:10.1016/j.jncc.2024.11.006
- Xue, P., Dang, L., Kong, L.-H., Tang, H.-P., Xu, H.-M., Weng, H.-Y., ... Zhao, F.-H. (2025). Deep learning enabled liquid-based cytology model for cervical precancer and cancer

- detection. *Nature Communications*, 16(1), 3506. doi:10.1038/s41467-025-58883-3
- Xue, P., Tang, C., Li, Q., Li, Y., Shen, Y., Zhao, Y., ... Zhao, F. (2020). Development and validation of an artificial intelligence system for grading colposcopic impressions and guiding biopsies. *BMC Medicine*, 18(1), 406. doi:10.1186/s12916-020-01860-y
- Yang, W., Jin, X., Huang, L., Jiang, S., Xu, J., Fu, Y., ... Meng, Y. (2024). Clinical evaluation of an artificial intelligence-assisted cytological system among screening strategies for a cervical cancer high-risk population. *BMC Cancer*, 24(1), 776. doi:10.1186/s12885-024-12532-y
- Ye, Z. C., Yang, Y. H., Xu, L., Wei, R. G., Ruan, X. L., Xue, P., ... Qiao, Y. L. (2025). Diagnostic performance evaluation of artificial intelligence-assisted diagnostic systems in cervical cytopathological examination. *Zhonghua Liu Xing Bing Xue Za Zhi = Zhonghua Liuxingbingxue Zazhi*, 46(3), 499–505. doi:10.3760/cma.j.cn112338-20240711-00412
- Ye, Z., Zhang, P., Wei, R., Niu, H., Li, H., Wang, M., ... Xue, P. (2025). Deep Learning-Assisted System Improves Practical Effects in Cervical Cytopathology Diagnosis: A Comparative Study of Reading Modes. *Modern Pathology*, 38(11), 100882. doi:10.1016/j.modpat.2025.100882
- Zampaoglou, E., Boureka, E., Gounari, E., Liasidi, P.-N., Kalogiannidis, I., Tsimitsiou, Z., ... Dagklis, T. (2025). Screening for Cervical Cancer: A Comprehensive Review of Guidelines. *Cancers*, 17(13). doi:10.3390/cancers17132072

Zhang, Y., Yuan, J., & Chen, L. (2026). Transforming cervical cancer pathological diagnosis through artificial intelligence: progress, performance, and barriers to clinical implementation. *Frontiers in Oncology*, 15. doi:10.3389/fonc.2025.1716018

OBSTETRİK YOĞUN BAKIMDA YAPAY ZEKÂ: ERKEN UYARI, KARAR DESTEK VE GÜVENLİ ENTEGRASYON

Kadir KABAHASANOĞLU¹

1. GİRİŞ

Obstetrik yoğun bakım; gebelik, doğum ve postpartum dönemde ortaya çıkan yaşamı tehdit eden komplikasyonlarda anne ve fetus için eş zamanlı risk yönetimi gerektiren, yüksek tempo ve yüksek belirsizlik içeren bir klinik alandır. Gebeliğe özgü fizyolojik adaptasyonlar (ör. hiperdinamik dolaşım, artmış oksijen tüketimi, değişen renal eşikler ve hiperkoagülabilité) klasik yoğun bakım eşiklerinin doğrudan uygulanmasını güçleştirir ve klinik kötüleşmeyi maskeleyebilir.^{1,2} Bu nedenle obstetrik hastalarda erken tanı, doğru triyaj ve zamanında müdahale; mortalite ve ciddi morbiditeyi azaltmada belirleyicidir.

Yapay zekâ (YZ) şemsiyesi altında yer alan makine öğrenmesi (MÖ) ve derin öğrenme yöntemleri, elektronik sağlık kayıtları (EHR), monitör dalga biçimleri, görüntüleme ve serbest metin notları gibi heterojen kaynaklardan öğrenerek klinik karar destek sistemlerine (KKDS) yeni bir kapasite kazandırmaktadır. Amaç; klinisyenin yerini almak değil, klinik iş akışına entegre edilen güvenilir ve izlenebilir risk kestirimleriyle hızlı karar vermeyi desteklemek, gereksiz alarmları azaltmak ve kaynakları doğru zamanda doğru hastaya yönlendirmektir.³

¹ Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Anesteziyoloji ve Reanimasyon Anabilim Dalı, Balıkesir, Türkiye, ORCID: 0009-0002-9045-5123.

Bununla birlikte, yoğun bakımda YZ uygulamalarının başarısı yalnızca model doğruluğuna değil; veri kalitesi, dış doğrulama, kalibrasyon, açıklanabilirlik, yanlılık (bias) kontrolü, siber güvenlik ve klinik etki değerlendirmesine de bağlıdır.³⁻⁶ Bu bölüm, obstetrik yoğun bakım bağlamında YZ'nin kanıta dayalı kullanım alanlarını ve güvenli entegrasyon için gerekli yöntemsel çerçeveyi sunmaktadır.

2. OBSTETRİK YOĞUN BAKIMIN ÖZGÜN GEREKSİNİMLERİ VE VERİ EKOSİSTEMİ

Obstetrik kritik hastalıkların çoğu, saatler içinde klinik tablo değiştirebilir. Postpartum kanama, hipertansif kriz/eklampsisi, maternal sepsis, amniyotik sıvı embolisi, peripartum kardiyak yetmezlik ve ARDS gibi tablolar hem hızlı kötüleşme hem de çoklu organ disfonksiyonu ile karakterizedir. Bu hastalarda klinik kararlar; hemodinamik, solunum, nörolojik ve koagülasyon verilerinin eş zamanlı yorumlanmasını gerektirir.^{1,2}

Yoğun bakım, “yüksek frekanslı veri üreten” bir ortamdır: monitörlerden saniyelik dalga biçimleri, laboratuvarlardan seri biyokimyasal ölçümler, ilaç/kan ürünleri uygulamalarından zaman damgalı kayıtlar ve serbest metin klinik notlar. Bu çok-modlu yapı, YZ için büyük bir fırsat yaratırken; eksik veri, ölçüm artefaktı, klinik uygulama farklılıkları ve etiket hataları gibi sorunları da beraberinde getirir. Kritik bakım araştırmalarında kullanılan büyük EHR veri setleri (ör. MIMIC-IV), bu tür çok kaynaklı verilerin araştırma amaçlı nasıl yapılandırılabileceğine dair önemli bir örnektir.⁷

Obstetrik popülasyonun genel yoğun bakım veri setlerinde az temsil edilmesi, gebeliğe özgü fizyoloji nedeniyle model genellenebilirliğinin düşmesi ve cinsiyet/gebelik temelli yanlılık riski, obstetrik yoğun bakımda YZ çözümlerinin yerel

veriyle geliştirilmesini veya en azından yerel doğrulama-yeniden kalibrasyon yapılmasını zorunlu kılar.^{4,5} Bu bağlamda, obstetrik yoğun bakımda karşılaşılan temel veri kaynakları, bunlara ait sık görülen sorunlar ve yapay zekâ modellemesi için kullanılabilecek pratik yaklaşımlar Tablo 1’de özetlenmiştir.

Tablo 1. Obstetrik yoğun bakımda veri kaynakları ve yapay zekâ açısından temel gereksinimler

Veri kaynağı	Örnek değişkenler	Sık sorunlar	YZ için pratik yaklaşım
Yaşam bulguları ve monitör trendleri	TA, MAP, HR, SpO ₂ , ısı; alarm kayıtları	Artefakt, sensör hatası, eksik veri	Kalite kontrol; zaman serisi modelleri; artefakt filtreleme
Dalga biçimleri (invaziv arter, ventilatör)	ABP waveform, pleth; ventilatör basınç/akım	Yüksek örnekleme hızı; cihazlar arası fark	Özellik çıkarımı; standardizasyon; kapalı döngü adayları
Laboratuvarlar	Hb, laktat, kreatinin, AST/ALT, trombosit, koagülasyon	Gebeliğe özgü referans aralıklar; gecikmeli sonuç	Gebelik-spesifik eşikler; dinamik değişim (delta) kullanımı
İlaç ve kan ürünleri kayıtları	Oksitosin, MgSO ₄ , vazopressör; eritrosit/FFP	Zaman damgası uyumsuzluğu; doz birimleri	İlaç-zaman serisi hizalama; olay tabanlı modelleme
Görüntüleme ve POCUS	EKO, akciğer US, FAST; BT/MR raporları	Operatör bağımlılığı; rapor heterojenliği	Görüntü + metin birleşik modeller; kalite skorları
Serbest metin klinik notlar	Hikâye, muayene, epikriz, konsültasyon	Kısaltmalar; dil çeşitliliği; gizlilik	NLP/LLM ile özetleme-etiketleme; de-identification

Kısaltmalar: TA: tansiyon arteriyel; MAP: ortalama arter basıncı; HR: kalp hızı; SpO₂: periferik oksijen satürasyonu; ABP: arter basınç dalga biçimi; FAST: Focused Assessment with Sonography in Trauma; NLP: doğal dil işleme; LLM: büyük dil modeli.

3. YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ: YOĞUN BAKIM UYGULAMASI İÇİN TEMEL KAVRAMLAR

YZ terimi; insan zekâsı gerektiren görevlerin (örüntü tanıma, sınıflama, tahmin, karar verme) bilgisayar sistemleriyle gerçekleştirilmesini ifade eder. MÖ, YZ'nin bir alt alanı olup; önceden tanımlanmış kurallar yerine veriden öğrenen modellerle çalışır. Derin öğrenme (DÖ) ise özellikle görüntü ve dalga biçimi gibi ham verilerde güçlü olan çok katmanlı sinir ağlarını kapsar. Doğal dil işleme (NLP) klinik notlardan yapılandırılmış bilgi çıkarmayı; pekiştirmeli öğrenme ise ardışık karar problemlerinde (ör. hemodinamik hedefleme) eylem-sonuç ilişkisini öğrenmeyi amaçlar.⁸

Obstetrik yoğun bakımda YZ'nin en yaygın çıktısı “risk skoru” veya “olay olasılığı”dır (ör. 6 saat içinde masif transfüzyon gereksinimi). Bu tür modellerde yalnızca ayırım gücü (AUC/C-istatistiği) değil; kalibrasyon (tahmin edilen risk ile gözlenen risk uyumu), karar eğrisi analiziyle klinik fayda (net benefit) ve belirli alt gruplarda performansın eşitliği (fairness) birlikte değerlendirilmelidir.⁹⁻¹²

Klinik uygulamada en kritik soru şudur: “Bu model, hangi koşulda hangi kararı değiştirecek ve sonuçta hastaya ne kazandıracak?” Bu nedenle model çıktısı; eyleme dönüştürülebilir eşikler, klinik protokollerle bağlantı ve kullanıcıya açıklanabilir bir gerekçe ile sunulmalıdır. Aksi halde yüksek doğruluk, klinik etkiye dönüşmeyebilir veya alarm yorgunluğunu artırabilir.^{3,6} Modellerin klinik kullanıma uygunluğunu belirlemek amacıyla, obstetrik yoğun bakımda YZ modelleri için dikkate alınması gereken temel performans ve güvenilirlik ölçütleri Tablo 2’de sunulmaktadır.

Tablo 2. Obstetrik yoğun bakımda YZ modelleri için performans ve güvenilirlik değerlendirmesi

Boyut	Ölçüt(ler)	Neden önemli?	Pratik öneri
Ayrım (discrimination)	AUC/C-istatistiği, duyarlılık-özgüllük, PPV/NPV	Olayı olan/olmayanı ayırabilme	Güven aralığı ver; prevalansa duyarlı metrikleri raporla
Kalibrasyon	Kalibrasyon eğrisi, kalibrasyon eğimi-kesimi, Brier skoru	Gerçek risk tahmini; eşik kararları için kritik	Yerel popülasyonda yeniden kalibrasyon planla
Klinik fayda	Karar eğrisi analizi (net benefit), eşik analizi	Yanlış pozitif/negatif dengesini klinik değerlerle ilişkilendirir	Eşik aralığını klinik protokole göre seç
Genellenebilirlik	Dış doğrulama (zaman/saha), alt grup analizleri	Farklı merkezlerde performans düşebilir	Prospektif ve çok merkezli doğrulama hedefle
Adalet ve yanlılık	Alt gruplarda performans farkı, kalibrasyon alt grup uyumu	Gebe-postpartum, yaş, komorbidite gibi gruplarda eşitlik	Yanlılık kaynağını tanımla; veriye/etikete müdahale et
Açıklanabilirlik	Özellik önemi, yerel açıklamalar (örn. SHAP), hata analizi	Klinik güven ve hata yakalama	Yanlış alarm örneklerini düzenli gözden geçir
Model kayması (drift)	Zaman içinde performans izlemi, veri dağılımı izlemi	Klinik protokol veya cihaz değişimleri modeli bozar	MLOps izlem panosu ve güncelleme politikası oluştur

Kısaltmalar: AUC: area under the curve; PPV: pozitif prediktif değer; NPV: negatif prediktif değer; SHAP: Shapley Additive Explanations; MLOps: Machine Learning Operations.

4. OBSTETRİK YOĞUN BAKIMDA YAPAY ZEKÂ UYGULAMA ALANLARI

Obstetrik yoğun bakımda YZ uygulamaları genellikle üç katmanda düşünülür: (i) erken uyarı ve risk kestirimi, (ii) tanı/yorumlama (görüntü, dalga biçimi, metin), (iii) tedavi optimizasyonu ve süreç yönetimi (örn. bundle uyumu, kaynak

planlama). Tablo 3, klinik senaryoları ve olası YZ çıktılarının pratik karşılıklarını özetlemektedir.

Tablo 3. Obstetrik yoğun bakımda öncelikli klinik senaryolar ve YZ çıktıları

Klinik senaryo	Klinik karar noktası	Başlıca veri kaynakları	Olası YZ çıktısı	Klinik kullanım notu
Kötüleşme / yoğun bakıma yatış ihtiyacı	Ekip çağırısı, seviye yükseltme, transfer	Yaşam bulguları, lab trendleri, notlar	Sürekli risk skoru; erken uyarı	Yanlış alarmı azaltmak için kalibrasyon + eşik yönetimi gerekir
Postpartum kanama ve masif transfüzyon	MTP aktivasyonu, kan ürünü hazırlığı, hedefe yönelik transfüzyon	Hb trendi, vital trend, kanama miktarı, TEG/ROTEM	Masif transfüzyon olasılığı; kan ürünü öneri desteği	Model, mevcut PPH protokolünü ikame etmez; hazırlığı hızlandırır
Hipertansif bozukluklar / HELLP	Antihipertansif titrasyonu, MgSO ₄ , doğum zamanlaması	TA trendi, lab (AST/ALT, Plt), semptom notları	Şiddetli özellik olasılığı; komplikasyon riski	Gebeliğe özgü eşikler ve dış doğrulama şart
Maternal sepsis	Antibiyotik-sıvı bundle, kültür, yoğun bakım izlemi	Vital, lab, mikrobiyoloji, notlar	Sepsis olasılığı; organ disfonksiyonu riski	Sepsis tanımı/etiketi heterojen; bias riski yüksek
Akut solunum yetmezliği / ARDS	Ventilatör ayarı, pronasyon, weaning	Ventilatör dalga biçimi, gazlar, görüntüleme	Oksijenasyon kötüleşme riski; asenkroni tespiti	Güvenlik için “insan-onayı” zorunlu tasarlanmalı
Peripartum kardiyak yetmezlik / şok	EKO, inotrop/vasopressör, mekanik destek	EKO, EKG, hemodinami, lab	Kardiyak disfonksiyon sınıflama; risk kestirimi	POCUS görüntü kalitesi değişken; kalite skoru eklenmeli

Kısaltmalar: MTP: masif transfüzyon protokolü; PPH: postpartum hemoraji; TEG: tromboelastografi; ROTEM: rotational tromboelastometri; Plt: trombosit; EKO: ekokardiyografi; EKG: elektrokardiyografi.


4.1. Erken uyarı ve klinik kötüleşmenin öngörülmesi

Eşik temelli erken uyarı sistemleri (örn. belirli TA/HR sınırları), obstetrik popülasyonda fizyolojik varyasyonlar nedeniyle yüksek yanlış-pozitif oranına ve alarm yorgunluğuna yol açabilir. YZ tabanlı yaklaşımlar, tek bir ölçüme dayanmak yerine trendleri, birlikte değişen parametreleri ve klinik bağlamı (örn. doğum sonrası kan kaybı, ilaç uygulamaları) dikkate alarak sürekli güncellenen bir risk skoru üretebilir. Böylece klinik ekibin “ne zaman” ve “kimi” yakından izleyeceği daha iyi hedeflenebilir. Bu tür sistemlerin güvenilirliği için kalibrasyon, dış doğrulama ve klinik iş akışına uygun eşik-eylem haritalaması zorunludur.^{3,11,12}

Bu nedenle birçok kurumda obstetriye uyarlanmış Maternal Early Warning Criteria (MEWC) gibi kriter setleri önerilmiş; ancak eşik-temelli yaklaşımların performansı ve klinik etkisi çalışmalar arasında heterojen bulunmuştur.^{13,14}

Şekil 1’de, obstetrik kritik hastada eşik-temelli alarm yaklaşımı ile YZ tabanlı sürekli risk kestiriminin klinik karar penceresini nasıl genişletebileceği şematik olarak gösterilmiştir.

Şekil 1. Eşik-temelli alarm ile YZ tabanlı sürekli risk kestiriminin karşılaştırılması (şematik).



Kısaltmalar: YZ: yapay zekâ.

Kutu 1. Klinik senaryo (erken uyarı)

34 yaş, G2P1, sezaryen sonrası 3. saatte. HR 112/dk, MAP 72 mmHg, laktat 2.1 mmol/L, Hb 10.2→9.4 g/dL. Eşik temelli alarm tek başına tetiklenmeyebilir. Trend-odaklı YZ skoru, kanama/hipovolemi olasılığını erken yükselterek kanama değerlendirmesi, uterotonik optimizasyonu ve kan ürünü hazırlığı için ekibi harekete geçirebilir.

4.2. Postpartum kanama, masif transfüzyon ve hemodinamik bozulma


Postpartum hemoraji (PPH) obstetrik kritik hastalıkların en önemli nedenlerinden biridir. Doğum kabulünde rutin olarak mevcut olan değişkenlerle PPH riskinin yüksek ayırım gücüyle öngörülebileceği gösterilmiştir; makine öğrenmesi modelleri, klasik lojistik regresyona kıyasla daha yüksek C-istatistiği ve daha iyi net fayda sunabilir.⁹ Klinik uygulamada bu tür skorlar; masif transfüzyon protokolünün (MTP) erken aktive edilmesi, kan bankası/ameliyathane hazırlığı, hızlı konsültasyon ve hedefe yönelik koagülasyon yönetimi (örn. TEG/ROTEM temelli) için kullanılabilir.¹⁵⁻¹⁷

DSÖ, postpartum kan kaybının nicel olarak değerlendirilmesini ve birinci yanıt tedavi paketinin (uterin masaj, uterotonik, traneksamik asit, intravenöz sıvı, muayene ve eskalasyon) hızla uygulanmasını öneren 2023 kılavuzunu yayımlamıştır; E-MOTIVE küme randomize çalışması bu yaklaşımın ciddi PPH sonuçlarını anlamlı biçimde azaltabildiğini göstermiştir.^{18,19}

Hemodinamik bozulma açısından, arteriyel dalga biçiminden hipotansiyonu dakikalar öncesinden öngören algoritmaların cerrahi popülasyonda yüksek performans gösterdiği bildirilmiştir.²⁰ Obstetrik hastada kanama ve vazodilatasyonun hızlı değişkenliği, bu yaklaşımın özellikle yüksek riskli sezaryen/kanama olgularında “önleyici

resüsitasyon” penceresi yaratma potansiyelini artırır (Şekil 2). Bununla birlikte, model çıktısı mutlaka klinisyen onayıyla ve mevcut PPH protokollerine entegre biçimde kullanılmalıdır.

Şekil 2. Postpartum kanama/şokta YZ destekli karar destek ve kapalı döngüye giden yol (konsept).



Kısaltmalar: PPH: postpartum hemoraji; MTP: masif transfüzyon protokolü; ABP: arter basınç dalga biçimi; TEG/ROTEM: viskoelastik testler; POCUS: yatak başı ultrason; YZ: yapay zekâ.

4.3. Hipertansif bozukluklar ve HELLP sendromu

Şiddetli preeklampsi/eklampsi ve HELLP sendromu; serebrovasküler olay, pulmoner ödem, akut böbrek hasarı ve koagülopati gibi hayatı tehdit eden komplikasyonlara ilerleyebilir. Uluslararası kılavuzlar; tanı-sınıflama, nöbet profilaksisi ve kan basıncı kontrolünün standartlaştırılmasını önermektedir.^{21,22} YZ modelleri; kan basıncı dinamikleri, laboratuvar trendleri ve semptom verilerini birleştirerek komplikasyon riskini daha erken ve kişiselleştirilmiş biçimde tahmin etmeyi hedefler. Burada kritik nokta, gebeliğe özgü normal aralıkların doğru modellenmesi ve “doğum zamanlaması” gibi yüksek etkili kararların mutlaka multidisipliner değerlendirme ile verilmesidir.

4.4. Maternal sepsis: tanım, saptama ve tedavi bundle’ları

DSÖ, maternal sepsisi gebelik, doğum veya postpartum dönemde enfeksiyona bağlı organ disfonksiyonu ile tanımlayan uluslararası bir tanım önermiştir.^{23,24} Genel popülasyonda Sepsis-3 çerçevesi organ disfonksiyonunu (SOFA) merkeze alır; ancak gebelikte fizyolojik değişkenlik, sepsis kriterlerinin yorumunu zorlaştırabilir.²⁵ Surviving Sepsis Campaign kılavuzları erken antibiyotik, sıvı resüsitasyonu ve hemodinamik hedefleri vurgular.²⁶ YZ tabanlı sepsis tahmin modelleri, heterojen verileri birleştirerek erken tanı penceresini genişletmeyi amaçlar; ancak sistematik derlemeler, bu modellerin çoğunda dış doğrulama ve raporlama eksikliği bulunduğunu göstermektedir.^{10,11}

Obstetrik sepsiste YZ’nin güvenli kullanımı için üç ilke önerilebilir: (i) tanım ve etiketlemenin standardizasyonu (maternal sepsis tanımı ve organ disfonksiyon bileşenleri), (ii) gebelik-spesifik kalibrasyon ve alt grup performansı, (iii) bundle uyumunu artıran iş akışı entegrasyonu (örn. antibiyotik-kültür-sıvı paketinin zamanında uygulanması).

4.5. Akut solunum yetmezliği/ARDS ve mekanik ventilasyon

Gebelikte artmış oksijen tüketimi ve azalmış akciğer rezervi, hipoksemiye toleransı azaltır; pulmoner ödem ve ARDS gelişimi hızlı olabilir.² YZ uygulamaları; ventilatör dalga biçimlerinden asenkroni tespiti, oksijenasyonun kötüleşme riskinin öngörülmesi ve weaning başarısının tahmini gibi alanlarda gelişmektedir. Bu tür karar destekler, özellikle obstetrik ARDS’de güvenlik açısından “insan-onayı” ve açık hata sınırlarıyla tasarlanmalıdır.

4.6. Kardiyovasküler komplikasyonlar ve yatak başı ultrason (POCUS)

Peripartum dönemde kardiyak disfonksiyon, pulmoner emboli ve şok ayırıcı tanısı hızlı yaklaşım gerektirir. POCUS/EKO, yoğun bakımda vazgeçilmez bir değerlendirme aracıdır; görüntü kalitesini otomatik değerlendiren ve temel ölçümleri kolaylaştıran YZ destekli yazılımlar, operatör bağımlılığını azaltma potansiyeli taşır. Ancak görüntü verisiyle çalışan modellerde cihaz-protokol farkları ve veri gizliliği gereksinimleri nedeniyle yerel doğrulama önemlidir.

5. MODEL GELİŞTİRME, DOĞRULAMA VE RAPORLAMA STANDARTLARI

Obstetrik yoğun bakımda YZ çalışmalarının yayınlanabilir ve klinik olarak güvenilir olması için, modelin nasıl geliştirildiği kadar nasıl raporlandığı da önemlidir. Son yıllarda, klinik tahmin modelleri ve YZ müdahaleleri için özel raporlama kılavuzları yayımlanmıştır: tahmin modelleri için TRIPOD+AI, risk-of-bias değerlendirmesi için PROBAST+AI; YZ içeren klinik araştırmalar için CONSORT-AI ve SPIRIT-AI;

erken aşama klinik değerlendirme için DECIDE-AI; model geliştirme raporlaması için MI-CLAIM.^{11,12,27-31}

Büyük dil modelleri (LLM) ile geliştirilen tahmin/çıkarım sistemlerinin raporlanması için TRIPOD-LLM gibi yeni uzantılar da tanımlanmaktadır.³²

Bu kılavuzların ortak vurguları; veri kaynağı ve seçim kriterlerinin şeffaf raporlanması, etiket tanımlarının netliği, eksik veri yönetimi, iç/dış doğrulama stratejileri, kalibrasyon raporlaması, hata analizi, insan-YZ etkileşimi ve klinik iş akışı tanımıdır. Obstetrik bağlamda ayrıca gebelik-spesifik referans aralıkları ve alt grup performansı kritik ek öğelerdir.^{11,12} Güncel literatürde öne çıkan bu raporlama kılavuzlarının kapsamı ve obstetrik yoğun bakım araştırmaları için taşıdıkları kritik gereksinimler Tablo 4'te ayrıntılı olarak listelenmiştir.

Tablo 4. Obstetrik yoğun bakımda YZ çalışmaları için raporlama ve kalite çerçeveleri

Kılavuz/araç	Kapsam	Ne zaman kullanılır?	Obstetrik yoğun bakım için kritik maddeler
TRIPOD (2015)	Klinik tahmin modeli raporlama	Regresyon veya temel MÖ tahmin modelleri	Model girdileri/çıktıları, doğrulama, kalibrasyon raporu
TRIPOD+AI (2024)	YZ tabanlı tahmin modelleri raporlama	MÖ/DÖ kullanan prognostik/diagnostik modeller	Veri akışı, ön-ışleme, dış doğrulama, alt grup performansı
PROBAST+AI (2025)	Risk-of-bias ve uygulanabilirlik	Tahmin modeli kalite değerlendirmesi	Etiket tanımı, sızıntı riski, analiz hataları
CONSORT-AI (2020)	YZ içeren RCT raporlama	YZ müdahalesi klinik sonuçları etkiliyor mu?	İnsan-YZ etkileşimi, hata analizleri, giriş/çıkışların tanımı
SPIRIT-AI (2020)	YZ içeren RCT protokol raporlama	Prospektif çalışma planlanırken	Veri edinimi, güncelleme politikası, güvenlik planı

DECIDE-AI (2022)	Erken aşama klinik değerlendirme	Pilot/feasibility aşaması	İş akışı uyumu, kullanıcı eğitimi, güvenlik sınırları
MI-CLAIM (2020)	Modelleme için asgari raporlama bilgisi	Model geliştirme/validasyon yayınları	Veri temsiliyeti, model açıklaması, tekrar üretilebilirlik
TRIPOD-LLM (2025)	LLM tabanlı tahmin/çıkarım modelleri için raporlama uzantısı	LLM kullanılarak geliştirilen/uygulanan klinik tahmin modelleri (özellikle serbest metin girdileri veya generatif bileşen içeren sistemler)	Prompt/çıktı güvenliği, halüsinasyon riski, sürümleme, veri sızıntısı ve gerçek iş akışında değerlendirme senaryoları raporlanmalı

Not: Kılavuzların ayrıntıları için ilgili orijinal yayınlara bakınız.^{11,12,27-31}

6. KLİNİK ENTEGRASYON: MLOps, İZLEM VE YÖNETİŞİM

Klinik yapay zekâ, “model geliştirme” ile bitmez; gerçek değer, klinik iş akışına güvenli entegrasyonla ortaya çıkar. Bu entegrasyon; veri toplama-ön işleme-model çıktısı-klinik eylem-geri bildirim döngüsünü ve sorumlulukların net tanımlandığı bir yönetim yapısını gerektirir (Şekil 3). FDA’nın iyi makine öğrenmesi uygulamaları (GMLP) yaklaşımı ve benzeri düzenleyici çerçeveler, ürün yaşam döngüsü boyunca kaliteyi vurgular.³³


Uygulamada önerilen asgari adımlar şunlardır: (1) Klinik problem ve eylem planının net tanımı, (2) Yerel veriyle dış doğrulama ve kalibrasyon, (3) Kullanıcı arayüzü ve insan faktörleri testi, (4) Prospektif pilot (DECIDE-AI) ve ardından etki değerlendirmesi, (5) Yaygın kullanımda sürekli performans izlemi (drift) ve güncelleme politikası.²⁹

Klinik karar destek araçlarının kanıt düzeyi ve değer önerisi; NICE Evidence Standards Framework gibi çerçevelerle değerlendirilerek, kullanılacağı risk sınıfına uygun klinik fayda

ve güvenlik kanıtı aranmalıdır.³⁴ Ayrıca FUTURE-AI uluslararası uzlaşılı kılavuzu, güvenilir ve uygulanabilir YZ araçları için yönetim, şeffaflık ve sürdürülebilirliğe odaklanan pratik ilkeler sunar.³⁵


Şekil 3, obstetrik yoğun bakımda YZ tabanlı KKDS'nin veri akışını ve geri bildirim döngüsünü; Şekil 4 ise klinik YZ yaşam döngüsü (MLOps) basamaklarını özetlemektedir.

Şekil 3. Obstetrik yoğun bakımda YZ tabanlı KKDS: veri-akışı ve klinik döngü (konsept).



Kısaltmalar: EHR: elektronik sağlık kaydı; KKDS: klinik karar destek sistemi; MÖ/DÖ: makine öğrenmesi/derin öğrenme; NLP: doğal dil işleme; YZ: yapay zekâ.

Şekil 4. Klinik yapay zekâ yaşam döngüsü (MLOps) ve yönetim basamakları (özet).



Kısaltmalar: MLOps: Machine Learning Operations; YZ: yapay zekâ.

Obstetrik yoğun bakımda ek bir gereksinim; obstetrik, anesteziyoloji-reanimasyon, yoğun bakım, neonatoloji,

hematoloji ve enfeksiyon hastalıkları gibi çok disiplinli ekiplerin aynı çıktıyı paylaşmasıdır. Bu nedenle YZ sisteminin çıktıları; herkesin anlayacağı ortak dilde, net eylem önerileri ve belirsizlik göstergeleriyle sunulmalıdır.

7. ETİK, HUKUKİ VE DÜZENLEYİCİ BOYUTLAR

Sağlıkta YZ uygulamalarında etik ilkeler; yararlılık, zarar vermeme, özerklik, adalet ve hesap verebilirlik ekseninde ele alınır. DSÖ, sağlık için YZ'nin etik ve yönetim çerçevesini yayımlamış; güvenlik, şeffaflık, açıklanabilirlik, insan denetimi ve kapsayıcılık gibi ilkeleri vurgulamıştır.³⁶

Düzenleyici alanda, AB Yapay Zekâ Yasası (AI Act) belirli YZ sistemlerini risk düzeyine göre sınıflandırarak yüksek riskli uygulamalarda sıkı gereksinimler (risk yönetimi, veri yönetimi, teknik dokümantasyon, şeffaflık ve insan gözetimi) öngörür.^{37,38} Bu çerçeveler, klinik kurumlarda YZ yönetimi ve sorumluluk paylaşımı (geliştirici-kurum-kullanıcı) için referans sağlar.

Yanlılık (bias) ve eşitsizlik riski, özellikle obstetrik popülasyonda belirgindir: veri setlerinin temsiliyeti, bakım süreçlerindeki yapısal farklılıklar ve etiket yanlılığı, algoritmanın bazı alt gruplarda sistematik olarak daha kötü performans göstermesine neden olabilir.^{4,5} Bu nedenle kalite izleme yalnızca “genel AUC” ile sınırlı kalmamalı; alt grup kalibrasyonu ve sonuç eşitliği düzenli olarak raporlanmalıdır. Tüm bu risklerin yönetilmesi ve güvenli bir klinik entegrasyon sağlanabilmesi için obstetrik yoğun bakıma özgü geliştirilen güvenlik ve yönetim kontrol listesi Tablo 5’te verilmiştir.

Tablo 5. Obstetrik yoğun bakımda YZ uygulamaları için güvenlik ve yönetim kontrol listesi

Risk alanı	Soru	Azaltma stratejisi
Veri gizliliği ve güvenlik	Kişisel sağlık verisi nasıl korunuyor?	De-identification; erişim kontrolü; güvenli loglama; siber güvenlik testleri
Temsiliyet ve yanlılık	Gebe-postpartum alt gruplar yeterli mi?	Alt grup performans raporu; yeniden örnekleme; fairness kısıtları
Etiket/sonuç tanımı	Sepsis/PPH gibi sonuçlar tutarlı mı?	Kılavuz-temelli tanımlar; çoklu kaynak doğrulaması; klinisyen incelemesi
Kalibrasyon ve eşik yönetimi	Risk skoru hangi eylemi tetikliyor?	Yerel kalibrasyon; karar eğrisi analizi; alarm eşiklerinin periyodik revizyonu
Açıklanabilirlik ve insan denetimi	Klinisyen çıktıyı anlayabiliyor mu?	Özellik katkısı, örnek vaka açıklamaları; insan-onayı gerektiren tasarım
Model kayması (drift)	Zamanla performans düşüyor mu?	Sürekli izlem; yeniden eğitim/güncelleme politikası; versiyonlama
Klinik etki ve sorumluluk	Hasta sonuçları iyileşiyor mu?	DECIDE-AI ile pilot; RCT/etki çalışması; sorumluluk matrisi
Kanıt standardı ve klinik değer	Modelin hedef popülasyonda klinik sonuç, iş yükü ve maliyet açısından net faydası gösterildi mi?	NICE Evidence Standards Framework'e göre kanıt düzeyi planla; DECIDE-AI sonrası pragmatik çalışma/RCT; değer temelli performans izlemi; uygulanabilirlik için FUTURE-AI ilkeleri

8. GELECEK PERSPEKTİFİ: TEMEL MODELLER, FEDERATED LEARNING VE “DİJİTAL İKİZ” YAKLAŞIMI

Son yıllarda büyük dil modelleri (LLM) ve çok-modlu temel modeller; metin, görüntü ve zaman serisini birlikte işleyebilme kapasitesiyle yoğun bakımda özetleme, klinik notlardan yapılandırılmış bilgi çıkarımı ve karar destek için yeni bir alan açmıştır. DSÖ, büyük çok-modlu modellerin sağlıkta

kullanımına ilişkin güvenlik, doğruluk ve yönetim gereksinimlerini vurgulayan güncel bir rehber yayımlamıştır.³⁹

Obstetrik yoğun bakımda gelecek vadede iki yaklaşım öne çıkmaktadır: (i) federated learning (federe öğrenme, veri yerinde kalarak işbirlikçi model eğitimi) ile kurumlar arası veri paylaşmadan ortak model eğitimi (gizlilik ve temsiliyet avantajı), (ii) bireysel hastanın fizyolojisini taklit eden “dijital ikiz” (digital twin) konseptiyle tedavi senaryolarının simülasyonu. Bu alanlarda en önemli gereksinimler; şeffaf raporlama, dış doğrulama, güvenlik sınırları ve klinik etki çalışmalarıdır.

9. SONUÇ

YZ, obstetrik yoğun bakımda erken uyarıdan süreç yönetimine uzanan geniş bir spektrumda klinik kararı destekleme potansiyeline sahiptir. Ancak gebeliğe özgü fizyoloji, veri temsiliyeti ve klinik etki gereksinimleri nedeniyle, bu sistemlerin güvenli kullanımı; yerel doğrulama-kalibrasyon, raporlama standartlarına uyum, etik-düzenleyici çerçeve ve sürekli izlem gerektirir. Klinisyen liderliğiyle kurulan disiplinler arası yönetim yapıları ve insan-merkezli tasarım ilkeleri, YZ’nin obstetrik kritik bakımda gerçek faydaya dönüşmesinin anahtarıdır.

KAYNAKLAR

1. Banerjee, A., & Cantellow, S. (2021). Maternal critical care: part I. *BJA education*, 21(4), 140–147. <https://doi.org/10.1016/j.bjae.2020.12.003>.
2. Soma-Pillay, P., Nelson-Piercy, C., Tolppanen, H., & Mebazaa, A. (2016). Physiological changes in pregnancy. *Cardiovascular journal of Africa*, 27(2), 89–94. <https://doi.org/10.5830/CVJA-2016-021>.
3. Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. *BMC medicine*, 17(1), 195. <https://doi.org/10.1186/s12916-019-1426-2>.
4. Celi, L. A., Cellini, J., Charpignon, M. L., Dee, E. C., Dernoncourt, F., Eber, R., Mitchell, W. G., Moukheiber, L., Schirmer, J., Situ, J., Paguio, J., Park, J., Wawira, J. G., Yao, S., & for MIT Critical Data (2022). Sources of bias in artificial intelligence that perpetuate healthcare disparities-A global review. *PLOS digital health*, 1(3), e0000022. <https://doi.org/10.1371/journal.pdig.0000022>.
5. Gianfrancesco, M. A., Tamang, S., Yazdany, J., & Schmajuk, G. (2018). Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. *JAMA internal medicine*, 178(11), 1544–1547. <https://doi.org/10.1001/jamainternmed.2018.3763>.
6. Amann, J., Blasimme, A., Vayena, E., Frey, D., Madai, V. I., & Precise4Q consortium (2020). Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC medical informatics and decision making*, 20(1), 310. <https://doi.org/10.1186/s12911-020-01332-6>.

7. Johnson, A. E. W., Bulgarelli, L., Shen, L., Gayles, A., Shammout, A., Horng, S., Pollard, T. J., Hao, S., Moody, B., Gow, B., Lehman, L. H., Celi, L. A., & Mark, R. G. (2023). MIMIC-IV, a freely accessible electronic health record dataset. *Scientific data*, 10(1), 1. <https://doi.org/10.1038/s41597-022-01899-x>.
8. Komorowski, M., Celi, L. A., Badawi, O., Gordon, A. C., & Faisal, A. A. (2018). The Artificial Intelligence Clinician learns optimal treatment strategies for sepsis in intensive care. *Nature medicine*, 24(11), 1716–1720. <https://doi.org/10.1038/s41591-018-0213-5>.
9. Venkatesh, K. K., Strauss, R. A., Grotegut, C. A., Heine, R. P., Chescheir, N. C., Stringer, J. S. A., Stamilio, D. M., Menard, K. M., & Jelovsek, J. E. (2020). Machine Learning and Statistical Models to Predict Postpartum Hemorrhage. *Obstetrics and gynecology*, 135(4), 935–944. <https://doi.org/10.1097/AOG.0000000000003759>.
10. Fleuren, L. M., Klausch, T. L. T., Zwager, C. L., Schoonmade, L. J., Guo, T., Roggeveen, L. F., Swart, E. L., Girbes, A. R. J., Thorat, P., Ercole, A., Hoogendoorn, M., & Elbers, P. W. G. (2020). Machine learning for the prediction of sepsis: a systematic review and meta-analysis of diagnostic test accuracy. *Intensive care medicine*, 46(3), 383–400. <https://doi.org/10.1007/s00134-019-05872-y>.
11. Collins, G. S., Moons, K. G. M., Dhiman, P., Riley, R. D., Beam, A. L., Van Calster, B., Ghassemi, M., Liu, X., Reitsma, J. B., van Smeden, M., Boulesteix, A. L., Camaradou, J. C., Celi, L. A., Denaxas, S., Denniston, A. K., Glocker, B., Golub, R. M., Harvey, H., Heinze, G., Hoffman, M. M., ... Logullo, P. (2024). TRIPOD+AI statement: updated guidance for reporting clinical

- prediction models that use regression or machine learning methods. *BMJ (Clinical research ed.)*, 385, e078378. <https://doi.org/10.1136/bmj-2023-078378>.
12. Moons, K. G. M., Damen, J. A. A., Kaul, T., Hooft, L., Andaur Navarro, C., Dhiman, P., Beam, A. L., Van Calster, B., Celi, L. A., Denaxas, S., Denniston, A. K., Ghassemi, M., Heinze, G., Kengne, A. P., Maier-Hein, L., Liu, X., Logullo, P., McCradden, M. D., Liu, N., Oakden-Rayner, L., ... van Smeden, M. (2025). PROBAST+AI: an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. *BMJ (Clinical research ed.)*, 388, e082505. <https://doi.org/10.1136/bmj-2024-082505>.
 13. Mhyre, J. M., D'Oria, R., Hameed, A. B., Lappen, J. R., Holley, S. L., Hunter, S. K., Jones, R. L., King, J. C., & D'Alton, M. E. (2014). The maternal early warning criteria: a proposal from the national partnership for maternal safety. *Obstetrics and gynecology*, 124(4), 782–786. <https://doi.org/10.1097/AOG.0000000000000480>.
 14. Chimwaza, Y., Hunt, A., Oliveira-Ciabati, L., Bonnett, L., Abalos, E., Cuesta, C., Souza, J. P., Bonet, M., Brizuela, V., Lissauer, D., & World Health Organization Global Maternal Sepsis Study Research Group (2024). Early warning systems for identifying severe maternal outcomes: findings from the WHO global maternal sepsis study. *EClinicalMedicine*, 79, 102981. <https://doi.org/10.1016/j.eclinm.2024.102981>.
 15. Committee on Practice Bulletins-Obstetrics (2017). Practice Bulletin No. 183: Postpartum Hemorrhage. *Obstetrics and gynecology*, 130(4), e168–e186. <https://doi.org/10.1097/AOG.0000000000002351>.

16. Consolidated guidelines for the prevention, diagnosis and treatment of postpartum haemorrhage. Geneva: World Health Organization; 2025. Licence: CC BY-NC-SA 3.0 IGO.
<https://iris.who.int/server/api/core/bitstreams/88bf11a5-93b6-4d6b-bdaa-856b46c8ed3c/content>.
17. Escobar, M. F., Nassar, A. H., Theron, G., Barnea, E. R., Nicholson, W., Ramasauskaite, D., Lloyd, I., Chandrachan, E., Miller, S., Burke, T., Ossanan, G., Andres Carvajal, J., Ramos, I., Hincapie, M. A., Loaiza, S., Nasner, D., & FIGO Safe Motherhood and Newborn Health Committee (2022). FIGO recommendations on the management of postpartum hemorrhage 2022. *International journal of gynaecology and obstetrics: the official organ of the International Federation of Gynaecology and Obstetrics*, 157 Suppl 1(Suppl 1), 3–50. <https://doi.org/10.1002/ijgo.14116>.
18. WHO recommendations on the assessment of postpartum blood loss and treatment bundles for postpartum haemorrhage. Geneva: World Health Organization; 2023. Licence: CC BY-NC-SA 3.0 IGO.
<https://iris.who.int/server/api/core/bitstreams/956e444f-3ac2-40cd-8b17-521f05770732/content>.
19. Gallos, I., Devall, A., Martin, J., Middleton, L., Beeson, L., Galadanci, H., Alwy Al-Beity, F., Qureshi, Z., Hofmeyr, G. J., Moran, N., Fawcus, S., Sheikh, L., Gwako, G., Oso, A., Aswat, A., Mammoliti, K. M., Sindhu, K. N., Podese, M., Horne, I., Timms, R., ... Coomarasamy, A. (2023). Randomized Trial of Early Detection and Treatment of Postpartum Hemorrhage. *The New England journal of medicine*, 389(1), 11–21. <https://doi.org/10.1056/NEJMoa2303966>.

20. Hatib, F., Jian, Z., Buddi, S., Lee, C., Settels, J., Sibert, K., Rinehart, J., & Cannesson, M. (2018). Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis. *Anesthesiology*, 129(4), 663–674. <https://doi.org/10.1097/ALN.0000000000002300>.
21. Gestational Hypertension and Preeclampsia: ACOG Practice Bulletin, Number 222. (2020). *Obstetrics and gynecology*, 135(6), e237–e260. <https://doi.org/10.1097/AOG.0000000000003891>.
22. Magee, L. A., Brown, M. A., Hall, D. R., Gupte, S., Hennessy, A., Karumanchi, S. A., Kenny, L. C., McCarthy, F., Myers, J., Poon, L. C., Rana, S., Saito, S., Staff, A. C., Tsigas, E., & von Dadelszen, P. (2022). The 2021 International Society for the Study of Hypertension in Pregnancy classification, diagnosis & management recommendations for international practice. *Pregnancy hypertension*, 27, 148–169. <https://doi.org/10.1016/j.preghy.2021.09.008>.
23. Evans, L., Rhodes, A., Alhazzani, W., Antonelli, M., Coopersmith, C. M., French, C., Machado, F. R., McIntyre, L., Ostermann, M., Prescott, H. C., Schorr, C., Simpson, S., Wiersinga, W. J., Alshamsi, F., Angus, D. C., Arabi, Y., Azevedo, L., Beale, R., Beilman, G., Belley-Cote, E., ... Levy, M. (2021). Surviving sepsis campaign: international guidelines for management of sepsis and septic shock 2021. *Intensive care medicine*, 47(11), 1181–1247. <https://doi.org/10.1007/s00134-021-06506-y>.
24. Bonet, M., Nogueira Pileggi, V., Rijken, M. J., Coomarasamy, A., Lissauer, D., Souza, J. P., & Gülmezoglu, A. M. (2017). Towards a consensus

- definition of maternal sepsis: results of a systematic review and expert consultation. *Reproductive health*, 14(1), 67. <https://doi.org/10.1186/s12978-017-0321-6>.
25. World Health Organization. (2017). *Statement on maternal sepsis* (WHO/RHR/17.02). <https://www.who.int/publications/i/item/WHO-RHR-17.02>.
26. Singer, M., Deutschman, C. S., Seymour, C. W., Shankar-Hari, M., Annane, D., Bauer, M., Bellomo, R., Bernard, G. R., Chiche, J. D., Coopersmith, C. M., Hotchkiss, R. S., Levy, M. M., Marshall, J. C., Martin, G. S., Opal, S. M., Rubenfeld, G. D., van der Poll, T., Vincent, J. L., & Angus, D. C. (2016). The Third International Consensus Definitions for Sepsis and Septic Shock (Sepsis-3). *JAMA*, 315(8), 801–810. <https://doi.org/10.1001/jama.2016.0287>.
27. Liu, X., Cruz Rivera, S., Moher, D., Calvert, M. J., Denniston, A. K., & SPIRIT-AI and CONSORT-AI Working Group (2020). Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. *Nature medicine*, 26(9), 1364–1374. <https://doi.org/10.1038/s41591-020-1034-x>.
28. Cruz Rivera, S., Liu, X., Chan, A. W., Denniston, A. K., Calvert, M. J., SPIRIT-AI and CONSORT-AI Working Group, SPIRIT-AI and CONSORT-AI Steering Group, & SPIRIT-AI and CONSORT-AI Consensus Group (2020). Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. *Nature medicine*, 26(9), 1351–1363. <https://doi.org/10.1038/s41591-020-1037-7>.

29. Vasey, B., Nagendran, M., Campbell, B., Clifton, D. A., Collins, G. S., Denaxas, S., Denniston, A. K., Faes, L., Geerts, B., Ibrahim, M., Liu, X., Mateen, B. A., Mathur, P., McCradden, M. D., Morgan, L., Ordish, J., Rogers, C., Saria, S., Ting, D. S. W., Watkinson, P., ... DECIDE-AI expert group (2022). Reporting guideline for the early stage clinical evaluation of decision support systems driven by artificial intelligence: DECIDE-AI. *BMJ (Clinical research ed.)*, 377, e070904. <https://doi.org/10.1136/bmj-2022-070904>.
30. Norgeot, B., Quer, G., Beaulieu-Jones, B. K., Torkamani, A., Dias, R., Gianfrancesco, M., Arnaout, R., Kohane, I. S., Saria, S., Topol, E., Obermeyer, Z., Yu, B., & Butte, A. J. (2020). Minimum information about clinical artificial intelligence modeling: the MI-CLAIM checklist. *Nature medicine*, 26(9), 1320–1324. <https://doi.org/10.1038/s41591-020-1041-y>.
31. Collins, G. S., Reitsma, J. B., Altman, D. G., & Moons, K. G. (2015). Transparent Reporting of a multivariable prediction model for Individual Prognosis or Diagnosis (TRIPOD): the TRIPOD statement. *Annals of internal medicine*, 162(1), 55–63. <https://doi.org/10.7326/M14-0697>.
32. Gallifant, J., Afshar, M., Ameen, S., Aphinyanaphongs, Y., Chen, S., Cacciamani, G., Demner-Fushman, D., Dligach, D., Daneshjou, R., Fernandes, C., Hansen, L. H., Landman, A., Lehmann, L., McCoy, L. G., Miller, T., Moreno, A., Munch, N., Restrepo, D., Savova, G., Umeton, R., ... Bitterman, D. S. (2025). The TRIPOD-LLM reporting guideline for studies using large language models. *Nature medicine*, 31(1), 60–69. <https://doi.org/10.1038/s41591-024-03425-5>.

33. International Medical Device Regulators Forum. (2025). *Good machine learning practice for medical device development: Guiding principles* (IMDRF/AIML WG/N88 FINAL: 2025). https://www.imdrf.org/sites/default/files/2025-02/IMDRF_AIML%20WG_GMLP_N88%20Final.pdf.
34. Sounderajah, V., Ashrafian, H., Darzi, A., Liu, X., Macdonald, T., Denniston, A. K., Ashurst, C., Weller, A., Holmes, C., Unsworth, H., Wolfram, V., Dillon, B., Salmon, M. & Greaves, F. (2022). *Developing evidence standards for artificial intelligence technologies within the NICE evidence standards framework for digital health technologies*. National Institute for Health and Care Excellence. <https://www.nice.org.uk/what-nice-does/digital-health/evidence-standards-framework-esf-for-digital-health-technologies>.
35. Lekadir, K., Frangi, A. F., Porras, A. R., Glocker, B., Cintas, C., Langlotz, C. P., Weicken, E., Asselbergs, F. W., Prior, F., Collins, G. S., Kaissis, G., Tsakou, G., Buvat, I., Kalpathy-Cramer, J., Mongan, J., Schnabel, J. A., Kushibar, K., Riklund, K., Marias, K., Amugongo, L. M., ... FUTURE-AI Consortium (2025). FUTURE-AI: international consensus guideline for trustworthy and deployable artificial intelligence in healthcare. *BMJ (Clinical research ed.)*, 388, e081554. <https://doi.org/10.1136/bmj-2024-081554>.
36. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization; 2021. Licence: CC BY-NC-SA 3.0 IGO. <https://iris.who.int/server/api/core/bitstreams/f780d926-4ae3-42ce-a6d6-e898a5562621/content>

37. European Parliament and Council of the European Union. (2024, July 12). *Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence and amending Regulations (EC) No 300/2008, (EU) No 167/2013, (EU) No 168/2013, (EU) 2018/858, (EU) 2018/1139 and (EU) 2019/2144 and Directives 2014/90/EU, (EU) 2016/797 and (EU) 2020/1828 (Artificial Intelligence Act)*. Official Journal of the European Union. <http://data.europa.eu/eli/reg/2024/1689/oj>.
38. European Commission. (2024, August 1). *European Artificial Intelligence Act comes into force* [Press release]. https://ec.europa.eu/commission/presscorner/detail/en/ip_24_4123.
39. Ethics and governance of artificial intelligence for health. Guidance on large multi-modal models. Geneva: World Health Organization; 2024. Licence: CC BY-NC-SA 3.0 IGO. <https://iris.who.int/server/api/core/bitstreams/e9e62c65-6045-481e-bd04-20e206bc5039/content>.

YAPAY ZEKA DESTEKLİ POSTPARTUM ANNE-BEBEK İZLEMİ: RUHSAL VE NÖROGELİŞİMSEL PERSPEKTİF

Merve DİLLİ GÜRKAN¹

1. GİRİŞ

Anne karnındaki dönemi de içine alan yaşamın ilk birkaç yılı, beyin gelişiminin en hızlı ve deneyime en açık olduğu dönemdir.(Dan, 2025) Bu süreçte şekillenen duygusal ve ilişkisel örüntüler, yalnızca bebeklik dönemini değil, yaşam boyu ruh sağlığını etkileyen biyopsikososyal temelleri oluşturur. Bu nedenle erken dönem ruh sağlığı, günümüzde önleyici psikiyatrinin en kritik odak alanlarından biri haline gelmiştir.(Nelson et al., 2025)

Bebek ruh sağlığı; yaşamın erken döneminde ortaya çıkan duygusal düzenleme, sosyal etkileşim, bilişsel organizasyon ve bağlanma süreçlerini kapsayan bütüncül bir gelişim alanıdır. Bu dönemde bebek duygularını deneyimleme, düzenleme ve ifade etme, güvenli ilişkiler kurma ve çevresini merakla keşfetme kapasitesini geliştirir.(Gleason & Finelli, 2025) Sağlıklı ruhsal gelişim gösteren bebekler, bakım verenlerine güvenle bağlanır, yaşına uygun biçimde duygu düzenleme becerileri sergiler, oyuna ve keşfe aktif olarak katılır ve stres karşısında belirli bir esneklik/dayanıklılık gösterebilir.(Lachman et al., 2024) Fetal dönemden itibaren sinir sisteminde başlayan sinaptogenez ve miyelinizasyon, doğumdan sonraki ilk aylarda ivmelenir; bu da deneyime çok duyarlı, aynı zamanda da kırılgan bir dönem

¹ Uz. Dr., Bandırma Eğitim ve Araştırma Hastanesi Çocuk ve Ergen Ruh Sağlığı Kliniği, ORCID: 0000-0002-0528-6373.

anlamına gelmektedir.(Dan, 2025) Bu dönemde bebeğin beslenmesi, bakım verenle teması, stres, enfeksiyon, ihmal gibi çevresel koşullar, beyin ağlarının ayrışma-bütünleşme dinamiklerini ve ilerideki bilişsel/duygusal sonuçları anlamlı biçimde etkileyerek kalıcı nörobiyolojik izler bırakır.(Luby et al., 2020; Nelson & Gabard-Durnam, 2020) Bebeğin erken dönem deneyimleri çocukluk, ergenlik ve hatta yetişkinlik dönemindeki psikopatoloji riskini kalıcı biçimde etkileyebilmektedir.(Nelson et al., 2025) Bu dönemdeki nörobiyolojik hassasiyet, bakım veren-bebek etkileşimini yalnızca psikososyal değil, aynı zamanda biyolojik bir düzenleyici haline getirmektedir. Dolayısıyla erken ilişkisel deneyimler, gelişmekte olan sinir sistemi için düzenleyici bir çevresel girdi işlevi görmektedir.(Fogel et al., 1997, 1999; Messinger et al., 2012) Perinatal dönemde ruhsal bozukluklarla mücadele eden annelerde; ebeveyn- çocuk ilişkilerinde bozulma riski bulunur.(Muzik & Borovska, 2010) Ebeveynde bu süreçte ruhsal bozukluk varlığında bebeklerde davranışsal, biyolojik ve nörofizyolojik düzeyde değişiklikler; duygusal reaktivitede artış, stres yanıt sisteminde düzensizlik ve sosyal etkileşimde güçlükler bildirilmiştir. Dahası, bu etkiler çocukluk ve ergenlik dönemine kadar sürebilmektedir.(Aktar et al., 2019; Hoffman et al., 2017) Bütün bunlar göz önünde bulundurulduğunda, perinatal dönem çocukta gelecekte ortaya çıkabilecek ruhsal bozuklukların risk ve koruyucu etmenlerini belirleyebilmek ve gerekli müdahaleleri planlamak için benzersiz bir “fırsat penceresi” niteliğindedir.(Luby et al., 2022; Racine et al., 2025) Ancak bu dönemde risklerin erken ve nesnel biçimde tanınması her zaman klinik gözlemlerle mümkün olmayabilmektedir.

Yapay zekâ; bu erken dönemde risk tanıma kapasitesini artırabilecek yeni bir araçtır. Perinatal maternal ruh sağlığını ve bebeğin nörodavranışsal örüntülerini analiz ederek klinik gözlemi destekleyebilecek yeni nesil bir izlem yaklaşımı sunmaktadır.

Yapay zekâ, perinatal dönemde anneye ait psikososyal ve biyolojik değişkenleri işleyerek ruhsal hastalık riskini öngörebilmekte; anne-bebek etkileşiminin kalitesi hakkında çıkarımlar sunabilmekte ve bebek ruh sağlığı izleminde erken uyarı sistemi işlevi görebilmektedir.(Anaduaka et al., 2025; Chen et al., 2025; Gau et al., 2023a; Messinger et al., 2009)

2. YAPAY ZEKA DESTEKLİ PERİNATAL MATERNAL RUH SAĞLIĞI İZLEMİ

Yapay zekâ, perinatal dönemde maternal ruh sağlığı izlemini özellikle erken risk saptama, objektiflik ve uzaktan sürekli izlem açısından belirgin biçimde güçlendirebilecek potansiyele sahiptir. Geleneksel yöntemler klinik ölçeklere ve dönemsel değerlendirmelere dayanırken, yapay zekâ tabanlı modeller dinamik davranışsal örüntüleri entegre ederek riskin zaman içindeki değişimini izleyebilmektedir. Bu dinamik izlem kapasitesi, erken müdahale olanağının artması ve yüksek riskli olguların daha hızlı belirlenmesi açısından özellikle önemlidir.(Ferrante et al., 2025) Yapay zekanın perinatal maternal ruh sağlığı alanında kullanımı ile ilgili sistematik derlemeler postpartum depresyonun en çok çalışılan alan olduğunu göstermektedir.(Xia et al., 2025)Postpartum depresyon, semptomlar ortaya çıktıktan sonra tanınırken, yapay zekâ tabanlı prediktif modeller, risk altındaki annelerin gebelik döneminde belirlenmesini ve hedefe yönelik erken müdahalelerin planlanmasını sağlayabilir.(Qi et al., 2025) Çok sayıda çalışma, makine öğrenmesi modellerinin perinatal depresyon ve anksiyete riskini klasik istatistiksel modellerden daha iyi öngörebildiğini bildirmektedir. (Anaduaka et al., 2025) Türkiye’de yürütülen bir çalışmada farklı makine öğrenmesi algoritmaları ile anksiyete ve depresyon ölçekleri kullanılarak perinatal depresyon ve anksiyete açısından riskli hastaları taramak amaçlanmıştır. Bu pilot

çalışmada, perinatal depresyon ve anksiyete belirtilerinin daha kısa sürede ve daha az maddeyle saptanmasını hedefleyen, özellik seçimi ve makine öğrenmesini Apache Spark tabanlı gerçek zamanlı büyük veri altyapısıyla entegre eden yapay zekâ destekli hibrit bir izlem sistemi geliştirilmiş; Naive Bayes modeli ile yaklaşık %91 doğruluk sağlanmıştır.(Oğur et al., 2023)

Perinatal dönemde ruhsal durumun anlık ve doğal bağlamda izlenebilmesi için öz-bildirime dayanmayan dijital veri kaynakları giderek daha fazla önem kazanmaktadır. Akıllı telefonlardan toplanan hareket(ivmeölçer), konum değişikliği, telefon kullanım süresi, uyku-uyanıklık paterni, sosyal etkileşim göstergeleri, arama/sms sıklığı gibi meta veriler yoluyla davranış örüntülerinden annenin ruhsal durumu hakkında ipuçları elde etmek ve anne ile bebeğin yakınlık kurduğu zamanların gün içindeki dağılımını belirlemek amacıyla yürütülen bir çalışmada telefondan toplanan pasif sensör verileri depresif belirtilerle anlamlı ilişkiler göstermiş ve kişiye özel, zamanında müdahale sunmak açısından faydalı bulunmuştur.(Byanjankar et al., 2021) Yine Nepal'in kırsal kesimlerinde genç ve ergen annelerle yapılan benzer bir pasif sensör çalışmasında ise standart psikolojik destek alan annelerin telefonlarından pasif veri toplanıp (hareket düzeyi, konum değişikliği, telefon kullanım sıklığı, sosyal etkileşim göstergeleri) bu veriler görselleştirilerek terapistle sunulmuş, terapistin de bu örüntülere göre seansı kişiselleştirebilmesi amaçlanmıştır. Bu verilerin seans içinde daha hedefli problem çözmeyi kolaylaştırdığı ve teknolojik olarak uygulanabilir olduğu sonucuna ulaşılmıştır.(van Heerden et al., 2024) Özellikle düşük ve orta gelirli ülkelerde bu teknolojik yaklaşımlar, ruh sağlığı hizmetlerine erişimdeki yapısal kısıtlılıkları azaltma potansiyeli taşımaktadır. Kenya'da yapılan bir müdahale çalışmasında, annelerin hamilelik ve doğum sonrası ruh sağlığını mobil uygulama yoluyla bildirdiği otomatik mesajlaşma temelli bir psikolojik destek sistemi geliştirilmeye

çalışılmış ve kullanan kadınlar tarafından yararlı bulunmuştur. Bu tür uygulamalar yüz yüze terapiye erişimi olmayan kadınlar için düşük maliyetli ve ölçeklenebilir bir alternatif sunmaktadır.(Green et al., 2020) Makine öğrenmesi algoritmaları, annenin postpartum ruh sağlığı, anneye ait psikososyal değişkenler ve demografik bilgilerden yola çıkarak bebek negatif duygulanımı, duygusal reaktivitesi, kendini düzenleme kapasitesi, aktivite düzeyi gibi karmaşık mizaç özelliklerini modelleyebilmekte ve gelişimsel riskin öngörülmesine katkı sağlayabilmektedir.(AlSaad et al., 2025) Bu tür bütüncül modellemeler, perinatal ruh sağlığının yalnızca anne odaklı değil, anne-bebek dyadı ekseninde ele alınmasına olanak tanıyarak erken gelişimsel risklerin daha hassas biçimde öngörülmesini mümkün kılmaktadır.

3. YAPAY ZEKA DESTEKLİ BEBEK RUH SAĞLIĞI İZLEMİ

Yaşamın ilk yılları, nörogelişimsel organizasyonun ve duygusal düzenleme kapasitesinin şekillendiği kritik bir dönemdir; bu süreçte erken risk faktörlerinin zamanında tanınması, ilerleyen dönem psikopatolojilerinin önlenmesi açısından belirleyici rol oynar. Geleneksel bebek ruh sağlığı izlemi büyük ölçüde klinik gözlem ve ebeveyn bildirimine dayanırken, yapay zekâ (YZ) destekli sistemler davranışsal, biyolojik ve çevresel verileri bütüncül biçimde analiz ederek erken risk örüntülerini daha hassas biçimde tanımlama potansiyeli sunmaktadır. Bu alanda YZ temelli yapılabilecekler birkaç başlık altında özetlenebilir.

3.1. Duygu ve Davranış İzleme

Bebek ağlamalarını derin öğrenme temelli hibrit bir modelle (Convolutional Neural Network, sesin spektral örüntülerini yakalamak için; Long Short-Term Memory ise

zaman içindeki değişimi analiz etmek amaçlı kullanılmıştır.) analiz ederek bebeğin ruh halini (açlık, ağrı, rahatsızlık gibi) otomatik sınıflandırmayı amaçlayan bir çalışmada bu hibrit model bebek ağlamalarını belirli kategorilerde yüksek doğruluk oranı ile sınıflandırabilmiştir. Bu gelişme yoğun bakımda/ev ortamında bebeğin ihtiyaçlarını erken belirlemek, mobil uygulamalara entegre edilerek ebeveyn rehberliği sağlamak, nörolojik/gelişimsel risk faktörü olabilecek ağlama paternlerini belirleyerek erken risk taramasında kullanmak açısından önemli bir bulgu olarak yorumlanmıştır.(G. A et al., 2024)

Gau ve arkadaşlarının (2023) çalışması, AffectNet isimli internet üzerinden toplanmış ve yedi temel yüz ifadesine göre etiketlenmiş geniş ölçekli bir yüz ifadesi veri setiyle geliştirilen ve mobil uygulamaya entegre edilen derin öğrenme tabanlı bir yüz ifadesi tanıma modelinin bebeklerde pozitif, negatif ve nötr duyguları %94'ün üzerinde doğrulukla sınıflandırabildiğini göstermiştir. Modelin mobil uygulamaya entegre edilmesi, YZ destekli yüz analizi sistemlerinin erken sosyo-duygusal gelişim taramasında nesnel, ölçeklenebilir ve klinik karar süreçlerini destekleyici bir araç olarak kullanılabileceğine işaret etmektedir.(Gau et al., 2023b) Yenidoğan yüz ifadesi analizi, YZ destekli erken izlem sistemlerinin temel taşlarından biri olabilir. Ancak bunu klinik bağlamda anlamlı kılmak için yüz ifadesi verisinin fizyolojik göstergeler (kalp hızı, ağrı skalaları, davranışsal gözlem) ile entegre edilmesi gerekir. Das ve arkadaşları tarafından gerçekleştirilen bir karşılaştırmalı çalışmada, yenidoğan yüz ifadelerinin derin öğrenme temelli farklı konvolüsyonel sinir ağı (CNN) mimarileri ile analiz edilmesi değerlendirilmiş; özellikle transfer öğrenme kullanılan ön-eğitilmiş modellerin, sınırlı veri setine rağmen neonatal yüzlerdeki ince mimik farklılıklarını daha yüksek doğrulukla sınıflandırabildiği gösterilmiştir.(Das et al., 2024) Bulgular, yüz temelli otomatik analiz sistemlerinin yenidoğanlarda ağrı ve

distres gibi sözel olarak ifade edilemeyen durumların nesnel biçimde izlenmesine katkı sağlayabileceğini ortaya koymakta, ancak bu tür yaklaşımların klinik karar süreçlerinde anlamlı kullanılabilmesi için fizyolojik ve davranışsal göstergelerle bütüncül biçimde değerlendirilmesi gerektiğine işaret etmektedir.(Das et al., 2024; Gau et al., 2023b)

3.2. Erken Risk Tespiti

Bebeklik dönemi, nörogelişimsel süreçlerin en hızlı ve plastisitenin en yoğun olduğu evreyi temsil ettiğinden, bu dönemde ortaya çıkan davranışsal ve biyolojik sapmaların erken dönemde nesnel yöntemlerle tespit edilmesi, uzun vadeli gelişimsel sonuçları belirleyici kritik bir fırsat alanı sunmaktadır.(Dan, 2025) Yapılan çalışmalar nörogelişimsel risklerin henüz klinik belirtiler tam olarak belirginleşmeden önce saptanabilmesi açısından yeni ve umut verici bulgular içermektedir.

Liu ve arkadaşları (2016), otizm spektrum bozukluğu(OSB) olan çocukların yüz işleme örüntülerindeki atipiklikleri göz izleme verileri üzerinden analiz ederek makine öğrenmesi temelli bir sınıflandırma modeli geliştirmiş ve bu modelin OSB'yi tipik gelişim gösteren çocuklardan anlamlı doğrulukla ayırt edebildiğini göstermiştir. Bu çalışma, yüz işleme farklılıklarının ölçülebilir bir davranışsal biyobelirteç olarak kullanılabileceğini ortaya koyarak sosyal biliş temelli yapay zekâ uygulamalarının erken tanı süreçlerine katkı sağlayabileceğini düşündürmektedir.(Liu et al., 2016) Davranışsal düzeydeki bu farklılıkların ötesinde, nörogörüntüleme temelli çalışmalar da OSB açısından erken gelişimsel sapmaların biyolojik temelini desteklemektedir. Hazlett ve arkadaşlarının çok merkezli boylamsal nörogörüntüleme verilerini kullandıkları bir çalışmada otizm açısından yüksek riskli bebeklerde 6–12 ay arasında kortikal yüzey alanında hızlanmış artışın ve bunu izleyen

dönemde toplam beyin hacminde aşırı büyümenin, 24. ayda konan OSB tanısı ile ilişkili olduğu gösterilmiştir. Bulgular, otizmde nöroanatomik farklılıkların doğuştan sabit anomalilerden ziyade erken yaşamda ortaya çıkan gelişimsel hız farklılıkları şeklinde seyrettiğini ortaya koymaktadır.(Hazlett et al., 2017) Benzer biçimde, sosyal belirtiler belirginleşmeden önce ortaya çıkabilecek biyobelirteçlere yönelik çalışmalar vokal üretim alanında da dikkat çekmektedir. Otizm spektrum bozukluğu (OSB) açısından yüksek riskli (OSB’li kardeşi olan) 6 aylık bebeklerin ağlama seslerinin akustik özelliklerinin tipik gelişim gösteren bebeklerden farklı olup olmadığını inceleyen bir çalışmada yüksek riskli bebeklerin ağlama seslerinde daha yüksek temel frekans ve artmış akustik düzensizlik gibi atipik özellikler saptanarak, nörogelişimsel farklılıkların sosyal belirtiler belirginleşmeden önce ses üretim sisteminde ortaya çıkabileceği gösterilmiştir.(Sheinkopf et al., 2012) Bu tarz yapay zekâ temelli örüntü tanıma sistemleri, çok boyutlu beyin verilerini davranışsal göstergelerle entegre ederek henüz OSB temel semptomlarının belirginleşmediği evrede risk tahmini yapılabilmesine olanak sağlayabilecek umut verici bir yaklaşım sunmaktadır.

OSB örneği, erken nörogelişimsel sapmaların ölçülebilir biyobelirteçler üzerinden saptanabileceğini göstermesi açısından önemli olmakla birlikte, benzer yaklaşımlar daha geniş nörolojik risk gruplarında da araştırılmaktadır. On sekiz ay altındaki bebeklerde ağlama akustiği ile nörolojik disfonksiyon arasındaki ilişkiyi inceleyen sistematik derleme ve meta-analiz bulguları, nörolojik risk altındaki bebeklerin daha yüksek ortalama ve minimum temel frekans (F0) ile hiperfonasyon ve biphonasyon gibi atipik melodik özellikler sergilediğini ortaya koymaktadır. (Lawford et al., 2022) Erken doğan bebeklerle yapılan başka bir çalışmada, taburculuk öncesinde kaydedilen ağlama seslerinin akustik özelliklerinin iki yaşta değerlendirilen dil, bilişsel ve

davranışsal sorunlarla anlamlı düzeyde ilişkili olduğu saptanmıştır.(Manigault et al., 2023) Bu bulgular, akustik ağlama analizinin erken dönemde nörolojik açıdan yüksek riskli bebeklerin belirlenmesinde hızlı, non-invaziv ve potansiyel olarak ölçeklenebilir bir tarama aracı olabileceğine işaret etmektedir.

Erken dönemde saptanabilen bu davranışsal ve vokal farklılıklar, gelişmekte olan beyin ağlarındaki yapısal ve fonksiyonel değişimlerle birlikte ele alındığında daha bütüncül bir risk modeli ortaya çıkmaktadır. Derin öğrenme modelleri, yenidoğan bebeklerin multimodal beyin MR verilerinden 2 yaş civarındaki bilişsel, dil ve motor nörogelişimsel sonuçları klinik olarak anlamlı doğrulukla tahmin edebilmektedir.(He et al., 2020, 2021; Lew et al., 2024) Yapılan bir derlemede, fetal dönemden erken çocukluk çağına uzanan nörogörüntüleme çalışmalarında makine öğrenmesi temelli öngörüselsel modellerin kullanımını kapsamlı biçimde ele alarak, erken beyin bağlantısallığı örüntülerinin ileriki bilişsel, davranışsal ve nörogelişimsel sonuçları tahmin etmede umut verici olduğunu, ancak küçük örneklemeler, aşırı uyum riski ve sınırlı dış doğrulama gibi metodolojik sorunların klinik uygulamaya geçişte önemli engeller oluşturduğunu vurgulamaktadır.(Scheinost et al., 2023)

3.3. Nörogelişimsel Takip

Erken çocukluk döneminde nörogelişimsel süreçlerin çok boyutlu ve hızlı bir biçimde şekillenmesi, davranışsal, biyolojik ve çevresel verilerin birlikte değerlendirilmesini gerektirmekte; bu bağlamda makine öğrenmesi temelli yaklaşımlar, karmaşık gelişimsel örüntüleri bütüncül biçimde analiz ederek bireyselleştirilmiş ve dinamik nörogelişimsel takip modellerinin geliştirilmesine olanak sağlamaktadır.(Benson et al., 2025) Bebeklere ait sağlık bilgi sistemlerinden elde edilen çok boyutlu verilerin makine öğrenmesi ve istatistiksel modelleme

yaklaşımlarıyla analiz edildiği bir çalışmada erken dönem klinik ve demografik göstergelerin bebeklerde bilişsel gelişim çıktılarıyla anlamlı biçimde ilişkili olduğu ortaya konmuştur.(Wang et al., 2022)

Nörogelişimsel takip yalnızca klinik verilerle değil, aynı zamanda bebeklerin spontan hareket örüntüleri aracılığıyla da gerçekleştirilebilmektedir.(ADDE et al., 2010; Airaksinen et al., 2022) Bu bağlamda geliştirilen akıllı bir giyilebilir sensör sistemi, bebeklerin motor gelişimini doğal yaşam ortamında izleyerek toplanan hareket verilerini makine öğrenmesi temelli algoritmalarla analiz etmiş ve motor repertuarın çeşitliliği ile olgunluk düzeyinin güvenilir biçimde nicel olarak belirlenebildiğini göstermiştir.(Abrishami et al., 2019; Airaksinen et al., 2022) Bulgular, laboratuvar dışı, sürekli ve nesnel veri toplama yaklaşımlarının erken nörogelişimsel takibi güçlendirebileceğini ve dijital pediatri uygulamalarında yeni bir izlem modeli sunabileceğini ortaya koymaktadır.

3.4. Anne-bebek Bağlanmasının Dijital Analizi

Anne-bebek bağlanması, yaşamın ilk yıllarında ruhsal düzenleme, sosyal gelişim ve nörobiyolojik olgunlaşma için temel bir yapı taşıdır. Anne-bebek bağlanmasının değerlendirilmesi gözleme dayalı ve klinik yoruma açık yöntemlere dayanırken, dijital görüntü analizi ve yapay zekâ temelli sistemler bu etkileşimin duygusal mikro-örüntülerini nesnel biçimde ölçme imkânı sunmaktadır. Bu bağlamda gerçekleştirilen bir pilot çalışma, anne-bebek etkileşimi sırasında ortaya çıkan yüz ifadelerinin otomatik yüz analizi algoritmalarıyla güvenilir şekilde saptanabildiğini göstererek, duygusal senkronizasyon, karşılıklılık ve yüz mimik eşleşmelerinin nicel olarak değerlendirilebileceğini ortaya koymuştur.(Messinger et al., 2009) Anne-bebek yüz yüze etkileşimini dinamik ve karşılıklı düzenlenen bir sistem olarak ele

alan çalışmalar, duygusal iletişimin sabit bir uyum durumundan ziyade mikro-zamansal düzeyde örgütlenen, esnek ve sürekli yeniden ayarlanan bir süreç olduğunu göstermektedir.(Fogel et al., 1997, 1999; Messinger et al., 2012) Anne ve bebeğin yüz ifadeleri, bakış yönü, vokalizasyonları ve duygu düzenleme örüntülerinin milisaniye düzeyinde analiz edildiği bir çalışma, anne-bebek etkileşiminin sürekli uyumdan ibaret olmadığını, kopma ve yeniden düzenlenme döngüleri üzerinden yapılandığını, bu etkileşimde bebeğin pasif bir alıcı değil aktif düzenleyici bir ajan olduğunu ortaya koymuştur.(Beebe et al., 2016) Bu çalışma, anne-bebek yüz yüze iletişimini dinamik sistemler perspektifiyle ele alması açısından önemlidir.

Ayrıca perinatal depresyon ve diğer psikiyatrik bozuklukların, annenin duyarlılığını ve bebeğiyle etkileşimini bozarak güvensiz ve dağınık bağlanma riskini artırdığı gösterilmiştir.(Grego et al., 2025) Makine öğrenmesi ve dijital fenotipleme ile postpartum depresyon riskinin çoklu dijital verilerden öngörülebilmesi, bağlanma sürecindeki olası bozulmaları klinik tablo ağırlaşmadan önce fark ederek anneyi yoğun bağlanma odaklı psikososyal müdahalelere yönlendirmeyi kolaylaştırabilmektedir.(AlSaad et al., 2025)

4. YAPAY ZEKANIN KLİNİK AVANTAJLARI

Geleneksel ruh sağlığı tarama ve tanı yöntemleri; doğrudan hasta-hekim iletişimi, davranışsal ve duygusal durum gözlemlerini ve hasta merkezli uygulamaları içermektedir.(Haberer et al., 2013) Sonuç olarak; klinik ruh sağlığı verileri genellikle karmaşık nicel verilerin yanı sıra geniş, yoğun nitel bilgiler içerir ve bu da zaman alıcı, emek isteyen bir iştir. Ayrıca potansiyel olarak önyargılı olabilen insan analizini gerektirir.(Palinkas, 2014) Yapay Zekâ, özellikle Makine Öğrenmesi ve Derin Öğrenme, çeşitli yönlerden karmaşık ve

yüksek boyutlu bu verileri işleme, analiz etme ve yorumlama konusundaki üstün yeteneği nedeniyle bu alanda önemli avantajlar sunmaktadır.(Jiang et al., 2017) İnsanların gözünden kaçabilecek gizli veri kalıplarını etkili bir şekilde ayırt edebilmekte ve bunları tahmin yapmada kullanabilmektedir. Bu yönüyle klinisyene yardımcı olan önemli bir araç haline gelmektedir.(Janiesch et al., 2021) Yapay zekanın perinatal izlemde kullanımı yalnızca risk tanımlamayla sınırlı kalmayabilir; önleyici ve müdahale odaklı kullanılabilir sistemler geliştirmek de mümkündür. Bazı pilot çalışmalar, annelerin ruhsal durumuna göre kişiselleştirilmiş psikolojik destek mesajları veya müdahale önerileri sunan hibrit modelleri denemekte, böylece klinik müdahalelerin zamanlamasını optimize etmektedirler. Bu tür uygulamalar, yapay zekanın yalnızca izleme değil, tedavi planlama ve bakım yönlendirme fonksiyonlarını da destekleyebileceğini göstermektedir.(van Heerden et al., 2024)

5. ETİK BOYUT, KLİNİK SORUMLULUK VE RİSKLER

Yapay zekâ uygulamalarının perinatal ruh sağlığı izlemi için gerçek klinik kullanımına geçişte etik, yasal ve pratik engeller de bulunmaktadır. Ruh sağlığı verileri en hassas veri türlerinden biridir ve ciddi gizlilik riskleri taşır. Kullanıcı gerçekten neyi paylaştığını biliyor mu? Veri nerede saklanıyor? Kimler erişebiliyor? Gibi sorular bu konuya hâlen temkinli yaklaşılmaya sebep olmaktadır.(Saeidnia et al., 2024) Bebek ruh sağlığı izlemi ise, zaten yüksek korunma gereksinimi olan bir grupta yürütüldüğü için genel ruh sağlığı-yapay zekâ tartışmalarındaki riskler daha da ağırlaşmaktadır. Genel olarak erken tanı ve klinik destek amaçlı kullanımı faydalı bulunsa da belli başlı konularda klinisyenler açısından riskli

bulunmaktadır.(Rogan et al., 2024) Bunlar şu maddelerle özetlenebilir:

- Mahremiyet ve veri güvenliği sorunu (hasta verilerinin kötüye kullanımı): Ruhsal belirtiler, aile dinamikleri ve ev içi kayıtlar son derece hassastır. Çocuk verilerinde gizlilik yükümlülükleri ise erişim, saklama ve ticari kullanımda ek sınırlamalar gerektirir.(Mansoor et al., 2025; Saeidnia et al., 2024)
- Aydınlatılmış onam ve özerklik: Bebek adına ebeveyn karar verir; uzun vadeli veri kullanımı ve model eğitimi için açık, anlaşılır, süreklilik içeren onam süreçleri gerekir.(Saeidnia et al., 2024; Turchioe et al., 2024)
- Mesleki otonominin kaybı, klinisyenin rolünün silikleşmesi ve insani/ilişkisel rolün zayıflaması(Aquino et al., 2023)
- Hatalı tanılama, aşırı müdahale ya da müdahalesizlik yani özetle yanlış pozitif/negatiflik (Koutsouleris et al., 2022)
- Klinik akışı bozan, rutine entegre edilemeyip iş yükünü arttıracak uygulamalar (Saeidnia et al., 2024)

Ayrıca yapay zekâ uygulamaları ancak eğitildikleri veri kadar adil olabilmektedir. Bu veriler azınlık gruplardan (göçmenler, düşük gelirli gruplar, perinatal dönem gibi) yetersiz alındığı için bu gruplarda eğitilebilirliği düşürüp yanlış risk tahmini yapabilir. Algoritmik yanlışlıklar, belirli sosyoekonomik veya kültürel alt grupların yanlış sınıflandırılması gibi riskleri beraberinde getirebilir; bu nedenle adil ve kapsayıcı veri setlerine dayanmak zorunludur.(Saeidnia et al., 2024)

Yapay zeka destekli sistemlerin klinik entegrasyonunu sağlamak, yalnızca teknik doğrulama ile mümkün değildir; ruh

sağlığı profesyonellerinin bu sistemlere olan güveni ve kabulü de kritik bir faktördür. Sistematik derlemeler göstermektedir ki klinisyenler, yapay zekâ ve pasif sensör sistemlerinin potansiyelini görmelerine rağmen, etik belirsizlikler, “kara kutu” algısı ve mesleki kontrol kaybı endişesi nedeniyle bu teknolojilere temkinli yaklaşmaktadırlar.(Rogan et al., 2024) Bu, yapay zekâ tabanlı izleme araçlarının “insan merkezli”, “şeffaf” ve “tedavi edici süreçle uyumlu” olacak şekilde tasarlanmasının gerekliliğini vurgulamaktadır. Ayrıca sistemin geliştirilmesinde ailelerin, klinisyenlerin ve etik uzmanlarının geliştirme ve uygulama sürecine sistematik katılımı yapay zekanın ruh sağlığı izleminde kullanılmasına dair güveni ve kabulü artıracaktır.(Tavory, 2024)

KAYNAKÇA

- Abrishami, M. S., Nocera, L., Mert, M., Trujillo-Priego, I. A., Purushotham, S., Shahabi, C., & Smith, B. A. (2019). Identification of Developmental Delay in Infants Using Wearable Sensors: Full-Day Leg Movement Statistical Feature Analysis. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1–7. <https://doi.org/10.1109/JTEHM.2019.2893223>
- Adde, L., Helbostad, J. L., Jensenius, A. R., Taraldsen, G., Grunewaldt, K. H., & Støen, R. (2010). Early prediction of cerebral palsy by computer-based video analysis of general movements: a feasibility study. *Developmental Medicine & Child Neurology*, 52(8), 773–778. <https://doi.org/10.1111/j.1469-8749.2010.03629.x>
- Airaksinen, M., Gallen, A., Kivi, A., Vijayakrishnan, P., Häyrynen, T., Ilén, E., Räsänen, O., Haataja, L. M., & Vanhatalo, S. (2022). Intelligent wearable allows out-of-the-lab tracking of developing motor abilities in infants. *Communications Medicine*, 2(1), 69. <https://doi.org/10.1038/s43856-022-00131-6>
- Aktar, E., Qu, J., Lawrence, P. J., Tollenaar, M. S., Elzinga, B. M., & Bögels, S. M. (2019). Fetal and Infant Outcomes in the Offspring of Parents With Perinatal Mental Disorders: Earliest Influences. *Frontiers in Psychiatry*, 10. <https://doi.org/10.3389/fpsy.2019.00391>
- AlSaad, R., Alabdulla, M., Tabassum, A., Sheikh, J., & Thomas, R. (2025). From mother to infant: predicting infant temperament using maternal mental health measures and tabular machine learning models. *Frontiers in Public Health*, 13. <https://doi.org/10.3389/fpubh.2025.1659987>

- Anaduaka, U. S., Oladosu, A. O., Katsande, S., Frempong, C. S., & Awuku-Amador, S. (2025). Leveraging artificial intelligence in the prediction, diagnosis and treatment of depression and anxiety among perinatal women in low- and middle-income countries: a systematic review. *BMJ Mental Health*, 28(1), e301445. <https://doi.org/10.1136/bmjment-2024-301445>
- Aquino, Y. S. J., Rogers, W. A., Braunack-Mayer, A., Frazer, H., Win, K. T., Houssami, N., Degeling, C., Semsarian, C., & Carter, S. M. (2023). Utopia versus dystopia: Professional perspectives on the impact of healthcare artificial intelligence on clinical roles and skills. *International Journal of Medical Informatics*, 169, 104903. <https://doi.org/10.1016/j.ijmedinf.2022.104903>
- Beebe, B., Messinger, D., Bahrnick, L. E., Margolis, A., Buck, K. A., & Chen, H. (2016). A systems view of mother–infant face-to-face communication. *Developmental Psychology*, 52(4), 556–571. <https://doi.org/10.1037/a0040085>
- Benson, F. N., Chelangat, D., Brink, W., Mwangala, P. N., Waljee, A. K., Moyer, C. A., & Abubakar, A. (2025). Application of machine learning in early childhood development research: a scoping review. *BMJ Open*, 15(8), e100358. <https://doi.org/10.1136/bmjopen-2025-100358>
- Byanjankar, P., Poudyal, A., Kohrt, B. A., Maharjan, S. M., Hagaman, A., & van Heerden, A. (2021). Utilizing passive sensing data to provide personalized psychological care in low-resource settings. *Gates Open Research*, 4, 118. <https://doi.org/10.12688/gatesopenres.13117.2>
- Chen, J., Wang, S., Lai, X., Zou, L., Wen, S. W., Krewski, D., Zhao, Y., Zhang, L., & Xie, R. (2025). Machine learning-

- based predictive model for postpartum post-traumatic stress disorder: A prospective cohort study. *Journal of Affective Disorders*, 390, 119935. <https://doi.org/10.1016/j.jad.2025.119935>
- Dan, B. (2025). The first 1000 days: A critical window for neurodevelopmental trajectories and interventions – and for parents. *Developmental Medicine & Child Neurology*, 67(9), 1108–1109. <https://doi.org/10.1111/dmcn.16386>
- Das, C., Nanda, D., Chatterjee, S., & Dutta, D. (2024). Comparative Analysis of Neonatal Facial Expression from Images using Deep Learning. *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1–7. <https://doi.org/10.1109/ICCCNT61001.2024.10725190>
- Ferrante, M., Vecchio, C., Rapisarda, P., & Oliveri Conti, G. (2025). Use of artificial intelligence to improve perinatal mental health: a systematic review. *European Journal of Public Health*, 35(Supplement_4). <https://doi.org/10.1093/eurpub/ckaf161.1930>
- Fogel, A., Dickson, K. L., Hsu, H., Messinger, D., Nelson-Goens, G. C., & Nwokah, E. (1997). Communication of smiling and laughter in mother-infant play: Research on emotion from a dynamic systems perspective. *New Directions for Child and Adolescent Development*, 197(77), 5–24. <https://doi.org/10.1002/cd.23219977702>
- Fogel, A., Messinger, D. S., Dickson, K. L., & Hsu, H. (1999). Posture and gaze in early mother–infant communication: synchronization of developmental trajectories. *Developmental Science*, 2(3), 325–332. <https://doi.org/10.1111/1467-7687.00078>

- G. A, S., S, G., Tharagarani, G., P, S., & B, S. (2024). An Automated Mood Analysis of Crying Infants Through Sound Recognition Using Hybrid Deep Learning. *2024 Third International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)*, 1–6.
<https://doi.org/10.1109/ICSTSN61422.2024.10671224>
- Gau, M.-L., Ting, H.-Y., Toh, T.-H., Wong, P.-Y., Woo, P.-J., Wo, S.-W., & Tan, G.-L. (2023a). Effectiveness of Using Artificial Intelligence for Early Child Development Screening. *Green Intelligent Systems and Applications*, 3(1), 1–13. <https://doi.org/10.53623/gisa.v3i1.229>
- Gau, M.-L., Ting, H.-Y., Toh, T.-H., Wong, P.-Y., Woo, P.-J., Wo, S.-W., & Tan, G.-L. (2023b). Effectiveness of Using Artificial Intelligence for Early Child Development Screening. *Green Intelligent Systems and Applications*, 3(1), 1–13. <https://doi.org/10.53623/gisa.v3i1.229>
- Gleason, M. M., & Finelli, J. (2025). Introduction to Infant and Early Childhood Mental Health. *Child and Adolescent Psychiatric Clinics of North America*, 34(2), 143–156.
<https://doi.org/10.1016/j.chc.2024.07.014>
- Green, E. P., Lai, Y., Pearson, N., Rajasekharan, S., Rauws, M., Joerin, A., Kwobah, E., Musyimi, C., Jones, R. M., Bhat, C., Mulinge, A., & Puffer, E. S. (2020). Expanding Access to Perinatal Depression Treatment in Kenya Through Automated Psychological Support: Development and Usability Study. *JMIR Formative Research*, 4(10), e17895. <https://doi.org/10.2196/17895>
- Grego, C. M., Araújo, C., & Tarelho, A. (2025). Perinatal Psychopathology and Bonding: Implications for Maternal-Infant Attachment and Infant Development.

- European Psychiatry*, 68(S1), S899–S900.
<https://doi.org/10.1192/j.eurpsy.2025.1826>
- Haberer, J. E., Trabin, T., & Klinkman, M. (2013). Furthering the reliable and valid measurement of mental health screening, diagnoses, treatment and outcomes through health information technology. *General Hospital Psychiatry*, 35(4), 349–353.
<https://doi.org/10.1016/j.genhosppsych.2013.03.009>
- Hazlett, H. C., Gu, H., Munsell, B. C., Kim, S. H., Styner, M., Wolff, J. J., Elison, J. T., Swanson, M. R., Zhu, H., Botteron, K. N., Collins, D. L., Constantino, J. N., Dager, S. R., Estes, A. M., Evans, A. C., Fonov, V. S., Gerig, G., Kostopoulos, P., McKinsty, R. C., ... Piven, J. (2017). Early brain development in infants at high risk for autism spectrum disorder. *Nature*, 542(7641), 348–351.
<https://doi.org/10.1038/nature21369>
- He, L., Li, H., Chen, M., Wang, J., Altaye, M., Dillman, J. R., & Parikh, N. A. (2021). Deep Multimodal Learning From MRI and Clinical Data for Early Prediction of Neurodevelopmental Deficits in Very Preterm Infants. *Frontiers in Neuroscience*, 15.
<https://doi.org/10.3389/fnins.2021.753033>
- He, L., Li, H., Wang, J., Chen, M., Gozdas, E., Dillman, J. R., & Parikh, N. A. (2020). A multi-task, multi-stage deep transfer learning model for early prediction of neurodevelopment in very preterm infants. *Scientific Reports*, 10(1), 15072. <https://doi.org/10.1038/s41598-020-71914-x>
- Hoffman, C., Dunn, D. M., & Njoroge, W. F. M. (2017). Impact of Postpartum Mental Illness Upon Infant Development. *Current Psychiatry Reports*, 19(12), 100.
<https://doi.org/10.1007/s11920-017-0857-8>

- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
- Koutsouleris, N., Hauser, T. U., Skvortsova, V., & De Choudhury, M. (2022). From promise to practice: towards the realisation of AI-informed mental health care. *The Lancet Digital Health*, 4(11), e829–e840. [https://doi.org/10.1016/S2589-7500\(22\)00153-4](https://doi.org/10.1016/S2589-7500(22)00153-4)
- Lachman, A., Gerber, B., Bornman, J., & Smythe, T. (2024). Opportunities to accelerate progress in infant mental health. *The Lancet Child & Adolescent Health*, 8(8), 551–552. [https://doi.org/10.1016/S2352-4642\(24\)00131-7](https://doi.org/10.1016/S2352-4642(24)00131-7)
- Lawford, H. L. S., Sazon, H., Richard, C., Robb, M. P., & Bora, S. (2022). Acoustic Cry Characteristics of Infants as a Marker of Neurological Dysfunction: A Systematic Review and Meta-Analysis. *Pediatric Neurology*, 129, 72–79. <https://doi.org/10.1016/j.pediatrneurol.2021.10.017>
- Lew, C. O., Calabrese, E., Chen, J. V., Tang, F., Chaudhari, G., Lee, A., Faro, J., Juul, S., Mathur, A., McKinstry, R. C., Wisnowski, J. L., Rauschecker, A., Wu, Y. W., & Li, Y. (2024). Artificial Intelligence Outcome Prediction in Neonates with Encephalopathy (AI-OPiNE). *Radiology: Artificial Intelligence*, 6(5). <https://doi.org/10.1148/ryai.240076>

- Liu, W., Li, M., & Yi, L. (2016). Identifying children with autism spectrum disorder based on their face processing abnormality: A machine learning framework. *Autism Research*, 9(8), 888–898. <https://doi.org/10.1002/aur.1615>
- Luby, J. L., Baram, T. Z., Rogers, C. E., & Barch, D. M. (2020). Neurodevelopmental Optimization after Early-Life Adversity: Cross-Species Studies to Elucidate Sensitive Periods and Brain Mechanisms to Inform Early Intervention. *Trends in Neurosciences*, 43(10), 744–751. <https://doi.org/10.1016/j.tins.2020.08.001>
- Luby, J. L., Rogers, C., & McLaughlin, K. A. (2022). Environmental Conditions to Promote Healthy Childhood Brain/Behavioral Development: Informing Early Preventive Interventions for Delivery in Routine Care. *Biological Psychiatry Global Open Science*, 2(3), 233–241. <https://doi.org/10.1016/j.bpsgos.2021.10.003>
- Manigault, A. W., Sheinkopf, S. J., Carter, B. S., Check, J., Helderman, J., Hofheimer, J. A., McGowan, E. C., Neal, C. R., O’Shea, M., Pastyrnak, S., Smith, L. M., Everson, T. M., Marsit, C. J., Dansereau, L. M., DellaGrotta, S. A., & Lester, B. M. (2023). Acoustic Cry Characteristics in Preterm Infants and Developmental and Behavioral Outcomes at 2 Years of Age. *JAMA Network Open*, 6(2), e2254151. <https://doi.org/10.1001/jamanetworkopen.2022.54151>
- Mansoor, M., Hamide, A., & Tran, T. (2025). Conversational AI in Pediatric Mental Health: A Narrative Review. *Children*, 12(3), 359. <https://doi.org/10.3390/children12030359>
- Messinger, D. S., Ekas, N. V., Ruvolo, P., & Fogel, A. D. (2012). “Are You Interested, Baby?” Young Infants Exhibit

- Stable Patterns of Attention During Interaction. *Infancy*, 17(2), 233–244. <https://doi.org/10.1111/j.1532-7078.2011.00074.x>
- Messinger, D. S., Mahoor, M. H., Chow, S., & Cohn, J. F. (2009). Automated Measurement of Facial Expression in Infant–Mother Interaction: A Pilot Study. *Infancy*, 14(3), 285–305. <https://doi.org/10.1080/15250000902839963>
- Muzik, M., & Borovska, S. (2010). Perinatal depression: implications for child mental health. *Mental Health in Family Medicine*, 7(4), 239–247.
- Nelson, C. A., & Gabard-Durnam, L. J. (2020). Early Adversity and Critical Periods: Neurodevelopmental Consequences of Violating the Expectable Environment. *Trends in Neurosciences*, 43(3), 133–143. <https://doi.org/10.1016/j.tins.2020.01.002>
- Nelson, C. A., Sullivan, E. F., & Valdes, V. (2025). Early adversity alters brain architecture and increases susceptibility to mental health disorders. *Nature Reviews Neuroscience*, 26(10), 642–656. <https://doi.org/10.1038/s41583-025-00948-9>
- Oğur, N. B., Çeken, C., Oğur, Y. S., Yuvaci, Hi. U., Yazici, A. B., & Yazici, E. (2023). Development of an Artificial Intelligence-Supported Hybrid Data Management Platform for Monitoring Depression and Anxiety Symptoms in the Perinatal Period: Pilot-Scale Study. *IEEE Access*, 11, 31456–31466. <https://doi.org/10.1109/ACCESS.2023.3262467>
- Palinkas, L. A. (2014). Qualitative and Mixed Methods in Mental Health Services and Implementation Research. *Journal of Clinical Child & Adolescent Psychology*, 43(6), 851–861. <https://doi.org/10.1080/15374416.2014.910791>

- Qi, W., Wang, Y., Wang, Y., Huang, S., Li, C., Jin, H., Zuo, J., Cui, X., Wei, Z., Guo, Q., & Hu, J. (2025). Prediction of postpartum depression in women: development and validation of multiple machine learning models. *Journal of Translational Medicine*, 23(1), 291. <https://doi.org/10.1186/s12967-025-06289-6>
- Racine, N., Premji, S., Plamondon, A., McDonald, S., Tough, S., & Madigan, S. (2025). Perinatal risk and protective factors associated with diagnosis of mental health disorders in children by age 9 years. *European Child & Adolescent Psychiatry*, 34(11), 3565–3575. <https://doi.org/10.1007/s00787-025-02759-w>
- Rogan, J., Bucci, S., & Firth, J. (2024). Health Care Professionals' Views on the Use of Passive Sensing, AI, and Machine Learning in Mental Health Care: Systematic Review With Meta-Synthesis. *JMIR Mental Health*, 11, e49577. <https://doi.org/10.2196/49577>
- Saeidnia, H. R., Hashemi Fotami, S. G., Lund, B., & Ghiasi, N. (2024). Ethical Considerations in Artificial Intelligence Interventions for Mental Health and Well-Being: Ensuring Responsible Implementation and Impact. *Social Sciences*, 13(7), 381. <https://doi.org/10.3390/socsci13070381>
- Scheinost, D., Pollatou, A., Dufford, A. J., Jiang, R., Farruggia, M. C., Rosenblatt, M., Peterson, H., Rodriguez, R. X., Dadashkarimi, J., Liang, Q., Dai, W., Foster, M. L., Camp, C. C., Tejavibulya, L., Adkinson, B. D., Sun, H., Ye, J., Cheng, Q., Spann, M. N., ... Westwater, M. L. (2023). Machine Learning and Prediction in Fetal, Infant, and Toddler Neuroimaging: A Review and Primer. *Biological Psychiatry*, 93(10), 893–904. <https://doi.org/10.1016/j.biopsych.2022.10.014>

- Sheinkopf, S. J., Iverson, J. M., Rinaldi, M. L., & Lester, B. M. (2012). Atypical Cry Acoustics in 6-Month-Old Infants at Risk for Autism Spectrum Disorder. *Autism Research*, 5(5), 331–339. <https://doi.org/10.1002/aur.1244>
- Tavory, T. (2024). Regulating AI in Mental Health: Ethics of Care Perspective. *JMIR Mental Health*, 11, e58493. <https://doi.org/10.2196/58493>
- Turchioe, M. R., Hermann, A., & Benda, N. C. (2024). Recentering responsible and explainable artificial intelligence research on patients: implications in perinatal psychiatry. *Frontiers in Psychiatry*, 14. <https://doi.org/10.3389/fpsyt.2023.1321265>
- van Heerden, A., Poudyal, A., Hagaman, A., Maharjan, S. M., Byanjankar, P., Bemme, D., Thapa, A., & Kohrt, B. A. (2024). Integration of passive sensing technology to enhance delivery of psychological interventions for mothers with depression: the StandStrong study. *Scientific Reports*, 14(1), 13535. <https://doi.org/10.1038/s41598-024-63232-3>
- Wang, S., Li, M., & Ng, S. B. (2022). Research on Infant Health Diagnosis and Intelligence Development Based on Machine Learning and Health Information Statistics. *Frontiers in Public Health*, 10. <https://doi.org/10.3389/fpubh.2022.846598>
- Xia, J., Chen, C., Lu, X., Zhang, T., Wang, T., Wang, Q., & Zhou, Q. (2025). Artificial intelligence-oriented predictive model for the risk of postpartum depression: a systematic review. *Frontiers in Public Health*, 13. <https://doi.org/10.3389/fpubh.2025.1631705>

OBSTETRİK VE JİNEKOLOJİK ANESTEZİDE YAPAY ZEKÂ: KARAR DESTEK, PROSEDÜREL YARDIM, OTOMASYON VE GÜVENLİ ENTEGRASYON

Muammer Hayri BEKTAŞ¹

1. GİRİŞ

Kadın doğum pratiğinde anesteziyoloji; gebeliğe özgü fizyolojik değişiklikler, anne-fetüs ikiliği, hızlı karar vermeyi gerektiren aciller ve multidisipliner ekip çalışması nedeniyle yüksek karmaşıklığa sahip bir alandır. Bu özellikler; sürekli izlem (monitorizasyon), erken uyarı, hataya dayanıklı iş akışı ve standardize karar verme ihtiyacını artırır. Son yıllarda obstetrik anesteziyoloji literatüründe YZ uygulamalarına yönelik anlatı derlemeler ve kavramsal çerçeveler hızla artmış; özellikle sezaryen spinal anestezisinde hipotansiyon öngörüsü, neuraksiyal ultrason görüntülerinde otomatik anatomik tanıma, postpartum hemoraji (PPH) risk tahmini ve perioperatif dokümantasyonda üretken YZ kullanımına dikkat çekilmiştir.¹⁻³

YZ tabanlı sistemler, klinisyenin yerini almak için değil; “görünmeyeni görünür kılmak” (erken risk sinyali), bilişsel yükü azaltmak (özetleme, kontrol listeleri), standardizasyonu artırmak (ölçeklerin tutarlılığı) ve zaman kritik kararlarda (vazopressör titrasyonu, masif kanama hazırlığı) karar desteği sağlamak için tasarlanmalıdır (Şekil 1).² Bu nedenle obstetrik/jinekolojik anestezide YZ’yi değerlendirirken iki soru merkezidir: (i) Model performansı iyi mi? (ii) Model, doğru

¹ Dr. Öğr. Üyesi, Bandırma Onyedİ Eylül Üniversitesi, Tıp Fakültesi, Anesteziyoloji ve Reanimasyon AD, ORCID: 0009-0009-7577-9171.


hastada doğru zamanda “klinik olarak anlamlı” bir iyileşme sağlıyor mu?

2. OBSTETRİK/JİNEKOLOJİK ANESTEZİDE YZ: TEMEL KAVRAMLAR, VERİ EKOSİSTEMİ VE DEĞERLENDİRME

2.1. Tanımlar ve model türleri

YZ, insan benzeri bilişsel görevleri (örüntü tanıma, sınıflama, tahmin, öneri üretme) gerçekleştirebilen algoritmalar bütünüdür. MO (machine learning, ML) veriden öğrenen modelleri; DO (deep learning, DL) ise çok katmanlı sinir ağlarıyla özellikle görüntü ve dalga şekli (waveform) verisinde güçlü yaklaşımları ifade eder. Üretken YZ (generative AI) ve büyük dil modelleri (LLM; large language model), serbest metinden özet çıkarma, dokümantasyon ve hasta iletişimi gibi alanlarda yeni fırsatlar sunar; ancak “hallucination” (uydurma bilgi üretimi), telif-kaynak atfı ve mahremiyet riskleri nedeniyle klinik kullanımda ek yönetim gerektirir.⁴⁻⁵

Şekil 1. Obstetrik/jinekolojik anesteziye YZ karar destek döngüsü



Çoklu-modal veri → ön işleme → model → çıktı → klinisyen eylemi → sonuç → geri besleme.

2.2. Veri kaynakları ve veri kalitesi

Obstetrik/jinekolojik anestezide YZ için başlıca veri kaynakları; preoperatif öykü ve muayene notları (serbest metin), laboratuvar sonuçları, vital bulgular ve hemodinamik dalga şekilleri (invaziv arter basıncı, fotopletimografi), anestezi bilgi yönetim sistemleri, ilaç/infüzyon logları, ultrason görüntüleri (neuraksiyal, havayolu, kardiyak/akciğer), ameliyathane zaman damgaları ve postoperatif ağrı-bulantı skorlarıdır (Tablo 1). Özellikle obstetrikte doğumhaneden ameliyathaneye hızlı geçişler ve acil durumlar, zaman damgası uyumunu daha kritik hâle getirir. Verinin doğruluğu (label kalitesi), eksik verinin yönetimi ve farklı cihaz-yazılım kaynaklarının standardizasyonu model performansını belirleyen temel faktörlerdir.

Tablo 1. Obstetrik ve jinekolojik anestezide YZ uygulamaları için veri kaynakları ve tipik görevler.


Veri kaynağı	Örnek içerik	Model/görev	Olası klinik çıktı
Yapılandırılmış EHR	Yaş, BMI, gebelik haftası, parity, tanılar, lab, ASA, planlanan cerrahi	Risk tahmini/sınıflama	PPH/hipotansiyon/ICU riski; hazırlık ve kaynak planlama
Serbest metin (preop notlar)	Komorbidite, ilaçlar, alerji, önceki anestezi, havayolu notu	NLP: bilgi çıkarımı/özetleme	Standart özet; ilaç etkileşimi uyarısı; ASA-PS önerisi
Fizyolojik dalga şekilleri	Arter basıncı, PPG, ECG, HRV, beat-to-beat değişkenlik	Zaman serisi modelleme	Hipotansiyon erken uyarısı; anomali saptama
Ultrason görüntüleri	Neuraksiyal, havayolu, akciğer/kalp USG kesitleri	Görüntü segmentasyonu/landmark tanıma	Midline-interspace; derinlik; iğne yolu rehberi
İlaç/infüzyon logları	Vazopressör dozu, anestezi ajan hızı, epidural pompa verisi	Kontrol/optimizasyon	Hedefte tutma (kapalı döngü); doz güvenlik alarmları
Hasta raporlu sonuçlar & uzaktan izlem	Ağrı-bulantı skorları, mobilizasyon, giyilebilir veriler	Tahmin + takip	Taburculuk sonrası risk sinyali; tele-izlem tetikleme

Nadir fakat yıkıcı olaylar (amniyotik sıvı embolisi, masif kanama, peripartum kardiyomiyopati dekompanzasyonu gibi) için örnek sayısı az olduğundan çok merkezli iş birlikleri önemlidir. Veri paylaşımının kısıtlı olduğu senaryolarda kurumlar arası ham veriyi taşımadan öğrenmeyi hedefleyen federated learning gibi yaklaşımlar, obstetrik anestezide gelecek vaat eden bir seçenektir.³

2.3. Model performansı: ayırım, kalibrasyon ve klinik fayda

Yüksek AUC/AUROC tek başına yeterli değildir. Klinik kullanım için kalibrasyon (tahmin olasılığı ile gerçek riskin uyumu), yanlış alarm yükü, karar eşiği seçimi ve klinik yarar (net benefit, decision curve) değerlendirilmelidir. Ayrıca, dağıtımdan sonra hasta profili veya uygulama değişiklikleriyle model performansı bozulabilir (“model sürüklenmesi”, drift). Bu nedenle performans izlemi, yeniden kalibrasyon ve güncelleme planı (versiyonlama) ürün yaşam döngüsünün parçası olmalıdır (Şekil 2).

Şekil 2. Klinik AI yaşam döngüsü ve yönetim: geliştirme → doğrulama → klinik değerlendirme → regülasyon → dağıtım → izlem/drift → güncelleme.



2.4. Kanıt kalitesi ve raporlama standartları

YZ çalışmalarının raporlanması ve metodolojik kalitesi için TRIPOD+AI (tahmin modelleri), PROBAST+AI (risk of bias), SPIRIT-AI/CONSORT-AI (protokol ve RCT raporlaması) ve DECIDE-AI (erken klinik değerlendirme) gibi standartların kullanılması önerilir (Tablo 2).⁶⁻¹⁰ Obstetrik/jinekolojik anesteziye YZ çalışmalarında ayrıca maternal ve neonatal sonuçlarının birlikte raporlanması, güvenlik olaylarının standart tanımlarla verilmesi ve alt grup analizleri (obezite, preeklampsi, acil-elektif gibi) kritik önemdedir.

Tablo 2. AI çalışmalarında raporlama/kanıt üretimi ve klinik entegrasyon için asgari kontrol listesi (özet).

Alan	Standart/çerçeve	Ne zaman kullanılır?	Kritik öğeler (özet)
Tahmin modeli raporlama	TRIPOD+AI	Model geliştirme/doğrulama çalışmaları	Veri tanımı, ön işleme, performans + kalibrasyon, klinik fayda
Risk of bias	PROBAST+AI	Yayın değerlendirme / sistematik derleme	Katılımcı, öngördürücüler, sonuç tanımı, analiz, uygunluk
Çalışma protokolü	SPIRIT-AI	AI içeren klinik çalışma protokolleri	AI sürümü, iş akış entegrasyonu, hata analizi, insan faktörleri
RCT raporlama	CONSORT-AI	AI içeren randomize çalışmalar	AI müdahalesi açıklığı, kullanım koşulları, kullanıcı etkileşimi, güvenlik
Erken klinik değerlendirme	DECIDE-AI	Pilot/erken uygulama çalışmaları	Güvenlik, iş akışı, uygulanabilirlik, iteratif iyileştirme
Dağıtım sonrası risk yönetimi	NIST AI RMF + PCCP yaklaşımı	Ürün yaşam döngüsü	Drift izlemi, olay bildirimi, versiyonlama, planlı güncelleme

2.5. Eğitim, simülasyon ve kalite iyileştirme

YZ destekli sistemler yalnızca “hasta başı” karar desteği değil; eğitim ve kalite iyileştirme için de kullanılabilir.

Neuraksiyal ultrason veya havayolu yönetiminde görüntü-temelli geri bildirim, simülatör senaryolarının kişiselleştirilmesi ve olgu sonrası otomatik raporlama; yeni başlayan hekimlerin öğrenme eğrisini kısaltabilir. Bu tür uygulamalarda hasta güvenliği açısından avantaj; gerçek zamanlı klinik karar yerine eğitim/geri bildirim odaklı olmalarıdır. Ancak eğitim verisinin temsiliyeti ve geribildirim doğruluğu, yanlış öğrenmeyi önlemek için düzenli olarak denetlenmelidir.¹

3. KLİNİK KARAR DESTEK VE RİSK STRATİFİKASYONU

3.1. Obstetrik hemoraji (PPH) ve yüksek riskli doğum: anestezi planlamasına yansımalar

PPH, maternal mortalite ve morbiditenin önde gelen nedenlerindendir. EHR tabanlı ML modelleri; doğum öncesi ve intrapartum değişkenleri birleştirerek PPH ve ilişkili ciddi maternal morbiditeyi öngörmeyi hedeflemektedir.¹¹⁻¹⁴ Anestezi açısından bu tür modeller; yüksek riskli olguda erken damar yolu planı, kan ürünlerinin hazır edilmesi, hücre kurtarma (cell salvage), invaziv monitorizasyon ve gerekirse doğumhane-ameliyathane-yoğun bakım koordinasyonunun erken başlatılmasına katkı sağlayabilir (Tablo 3). Örneğin, ciddi morbiditeyle ilişkili PPH'yi hedefleyen yorumlanabilir ML yaklaşımları; risk faktörlerinin şeffaf biçimde sunulması (SHAP vb.) yoluyla klinik kabul edilebilirliği artırmayı amaçlamaktadır.¹³

Tablo 3. YZ destekli risk stratifikasyonunun anestezi kararlarına olası yansımaları (örnek senaryolar).

Hedef olay/senaryo	Tipik girdiler	YZ çıktısı (örnek)	Anestezi ekibi için eylem (örnek)
Postpartum hemoraji / plasenta akreta spektrumu	EHR, obstetrik öykü, USG/plasenta bulguları, lab	Risk olasılığı + katkı faktörleri	Kan ürünleri/ MTP hazırlığı; invaziv monitorizasyon; ekip koordinasyonu
Spinal hipotansiyon (sezaryen)	Bazal BP/HR, dalga şekli özellikleri, BMI, uterotonikler	Erken uyarı; vazopressör ihtiyacı kestirimi	Profilaktik VP stratejisi; hedef basınç; sık izlem
Zor havayolu (gebelik)	Klinik ölçümler, (varsa) yüz görüntüsü/USG ölçümleri, geçmiş kayıt	Zorluk olasılığı	Hazırlık: plan A-B-C; VL/SGA hazır; deneyimli ekip çağırısı
Preeklampsi/HELLP ve kardiyak risk	BP trendleri, lab, komorbidite, EHR metni	ICU ihtiyacı/komplikasyon riski	Sıvı kısıtlı yaklaşım; invaziv izlem; post-op yakın takip
Şiddetli postoperatif ağrı (sezaryen/jinekoloji)	Önceki ağrı öyküsü, anksiyete, opioid tüketimi, cerrahi süre	Şiddetli ağrı olasılığı	Multimodal analjezi; rejyonal blok; yakın izlem/tele-izlem
PONV (özellikle jinekolojik laparoskopi)	Cinsiyet, PONV öyküsü, opioid dozu, cerrahi süre, profilaksi	PONV riski + öneri	Kişiselleştirilmiş antiemetik protokol; opioid azaltma
Beklenmeyen kritik bakım ihtiyacı	EHR + intraop trendler + lab	ICU/HDÜ olasılığı	Erken yatak planı; hemodinamik/solunum optimizasyonu

Bununla birlikte PPH modellerinin bir kısmı retrospektiftir; dış doğrulama ve klinik etki çalışmaları sınırlıdır. Bu nedenle risk skorları “tek başına karar” değil, masif kanama protokollerini tetikleyen çok katmanlı bir güvenlik sistemi olarak kurgulanmalıdır.¹¹ Ayrıca anestezinin klinik hedefi yalnızca kan kaybını tahmin etmek değil; hemodinamik stabiliteyi ve organ perfüzyonunu korurken transfüzyon stratejisini uygun biçimde yönetmektir. Gelecekte AI, tromboelastografi (TEG/ROTEM), seri hemoglobin ölçümleri ve hemodinamik dalga şekillerini birleştirerek “dinamik” transfüzyon karar desteğine evrilebilir (Tablo 4).

Tablo 4. İntraoperatif hemodinamik yönetimde YZ ve otomasyon: hedef değişkenler, algoritmik kontrol ve güvenlik sınırları.

Klinik sorun	İzlenen sinyal/veri	Algoritma tipi (örnek)	Eylem/çıktı	Güvenlik sınırları (örnek)
Spinal hipotansiyon öngörüsü	Arter basınç dalga şekli, bazal BP/HR	ML erken uyarı	Uyarı + önerilen VP stratejisi	Hedef dışına çıkınca manuel değerlendirme; bradikardi uyarısı
Vazopressör otomasyonu	Sistolik/MA P trendi	Kapalı döngü kontrol	VP infüzyon hız ayarı	Maksimum doz; hipertansiyon/bradikardi kesme kuralı; override
Sıvı yönetimi	PPV/SVV, USG bulguları, idrar çıkışı	Tahmin/optimizasyon	Sıvı bolusu önerisi	Preeklampside sıvı kısıt; pulmoner ödem uyarısı
Masif kanama yönetimi	Kanama miktarı, lab, TEG/ROTEM, hemodinamik trend	Karar destek	MTP aktivasyonu; ürün oranı önerisi	Klinik doğrulama; yanlış pozitif/negatif değerlendirmesi
PACU/serviste bozulma	Vital trend, ağrı, O ₂ sat., mobilizasyon	Anomali saptama	Ekip uyarısı/yeniden değerlendirme	Alarm eşiği; hasta kaygısı/yanlış alarm yönetimi

3.2. Preeklampsi/HELLP ve komorbiditeler: perioperatif risk profili

Preeklampsi, trombositopeni, kardiyak hastalık ve obezite gibi durumlar; neuraksiyal anestezi uygunluğu, sıvı-vazopressör dengesi, perioperatif ventilasyon ve postoperatif izlem düzeyini belirler. NLP tabanlı araçlar, serbest metinlerden komorbidite ve risk faktörlerini çıkararak standardize risk profili oluşturabilir; bu profil doğumhane kaynak planlaması (monitorizasyon, yoğun bakım yatağı) ve konsültasyon süreçlerini hızlandırabilir.¹⁵⁻¹⁶

3.3. Zor havayolu öngörüsü: görüntü analizi ve çoklu-modal yaklaşımlar

Gebede havayolu yönetimi, hızlı oksijen desatürasyonu ve aspirasyon riski nedeniyle daha yüksek risk taşır. Obstetrik genel anesteziye zor/başarısız entübasyon yönetimine ilişkin

algoritmalar OAA/DAS kılavuzlarında detaylandırılmıştır.¹⁷ YZ bu alanda; yüz görüntüsü analizi, videolaringoskop görüntüsünden zorluk tahmini veya ultrason ölçümleri gibi verileri birleştirerek “zorluk olasılığı” üretebilir. Yüz görüntülerini kullanan DL modelleriyle videolaringoskopide zorluk tahmininin mümkün olduğu gösterilmiştir.¹⁸ Ancak mahremiyet (biyometrik veri), aydınlatılmış onam, etnik/antropometrik çeşitlilik ve yanlış negatif/pozitif sonuçların hasta güvenliğine etkisi nedeniyle bu modeller; yalnızca kılavuz-temelli hazırlığı destekleyen bir “hazırlık artırıcı” modül olarak düşünülmelidir. Güncel klinik pratikte ise, zor havayolu yönetimi için kanıta dayalı yaklaşım ASA ve obstetrik spesifik kılavuzlarla uyumludur; YZ araçlarının bu kılavuzlara gömülü şekilde çalışması güvenlik açısından daha rasyoneldir.^{17,19}

3.4. Jinekolojik cerrahide risk öngörüsü ve perioperatif kaynak yönetimi

Jinekolojik cerrahi; laparoskopik/robotik girişimler, endometriozis cerrahisi, jinekolojik onkoloji (sitoredüktif cerrahi) gibi geniş bir spektrumu kapsar. Bu olgularda; PONV, postoperatif ağrı, pulmoner komplikasyon, tromboemboli ve kanama riski belirgin olabilir. YZ tabanlı risk modelleri; cerrahi türü, Trendelenburg süresi, opioid dozu, komorbidite yükü ve laboratuvar değişkenlerini birleştirerek (i) kişiselleştirilmiş antiemetik-analjezik planı, (ii) hedefe yönelik tromboprofilaksi değerlendirmesi, (iii) yoğun bakım ihtiyacı olasılığı gibi çıktılarla kaynak yönetimine katkı sağlayabilir (Tablo 3). Bu alanda kanıt hızla gelişmekle birlikte, klinik etkiyi gösteren prospektif çalışmaların sayısı hâlâ sınırlıdır.

4. NEURAKSİYAL ANESTEZİ VE DOĞUM ANALJEZİSİNDE YZ

4.1. AI destekli neuraksiyal ultrason: otomatik landmark tanıma ve derinlik hesaplama

Obezite, skolyoz veya bel anatomisinin zor olduğu durumlarda neuraksiyal girişimler güçleşir. Ultrason rehberli neuraksiyal yaklaşımın başarısız girişim ve ponksiyon sayısını azaltabileceğine dair kanıt artmaktadır.²⁰ YZ, ultrason görüntüsünde kemik-yumuşak doku kontrastını artırma, orta hat ve interlaminar aralıkların otomatik tanınması, epidural aralığa tahmini derinlik ölçümü ve iğne giriş açısı önerisi gibi işlevlerle “operatör bağımlılığını” azaltmayı hedefler. Bölgesel anestezide ultrason yorumunu destekleyen AI sistemlerine ilişkin kapsamlı bir tarama, doğruluk ve klinik yararın değerlendirilmesinde standart bir metodoloji ihtiyacını vurgulamıştır.²¹

Klinik kullanım eşiğini düşürmeyi amaçlayan Accuro gibi cihazlar, neuraksiyal ultrason için otomatik landmark tanıma ve derinlik ölçümü sunar.²² Bu tür sistemler; özellikle eğitim sürecinde “ikinci göz” doğrulama, zorlu anatomide hızlı hedefleme ve girişim sayısını azaltma potansiyeli taşır. Ancak cihaz-merkezli algoritmaların farklı popülasyonlarda (gebelik, obezite, skolyoz) performansı ve maliyet-etkinliği, yerel veriyle değerlendirilmelidir (Tablo 5).


Tablo 5. Neuraksiyal anestezi ve doğum analjezisi için YZ uygulamaları: kullanım alanları, kazanımlar ve sınırlılıklar.

Kullanım alanı	Teknik yaklaşım/örnek	Beklenen kazanım	Sınırlılıklar ve güvenlik notu
AI destekli neuraksiyal USG	Landmark tanıma, midline/interspace, derinlik ölçümü (öm. cihaz tabanlı çözümler)	Daha az ponksiyon; daha hızlı yerleştirme; eğitim desteği	Popülasyonlar arası performans; operatör gözetimi zorunlu
İğne yolu/başarı rahmini	Görüntü + klinik değişkenlerle ML	Epidural başansızlık riskini azaltma	Prospektif etki verisi sınırlı; yanlış güven hissi riski
Komplikasyon erken uyarısı	Vital trend + pompa logları ile anormali saptama	Yüksek blok/solumum depresyonu erken saptama	Alarm yorgunluğu; eylem protokolü şart
Dokümantasyon ve kontrol listeleri	LLM ile özetleme/şablon doldurma	Zaman tasarrufu; standardizasyon	Hallucination; kaynak/versiyon kontrolü; insan onayı şart

4.2. Doğum analjezisi: komplikasyon öngörüsü ve kişiselleştirme

Doğum analjezisi (epidural veya kombine spinal-epidural) sırasında YZ'nin katkısı yalnızca yerleştirme kolaylığı ile sınırlı değildir. Epidural ilişkili maternal ateş gibi olaylar için ML tabanlı öngörü modelleri geliştirilmekte; erken tanı ve gereksiz antibiyotik/yenidoğan sepsis değerlendirmelerini azaltma potansiyeli tartışılmaktadır.¹ Gelecekte, hasta kontrollü epidural analjezi verisi, uterin kontraksiyon örüntüleri ve maternal vital bulguların birleştirilmesiyle analjezi dozlarının daha dengeli titrasyonu mümkün olabilir. Bununla birlikte obstetrikte kapalı döngü analjezi uygulamalarının yaygınlaşması; güvenlik sınırlarının tanımlanması (maksimum lokal anestezi/opioid dozu, yüksek blok uyarısı), klinik çalışma kanıtı ve regülasyon süreçlerine bağlıdır (Şekil 3; Tablo 5).

Şekil 3. AI destekli neuraksiyal ultrason ve doğum analjezisi iş akışı.



4.3. POCUS (akciğer/kardiyak) ve YZ: obstetrik özel senaryolar

Obstetrik anestezide point-of-care ultrasonografi (POCUS); preeklampside pulmoner ödem değerlendirmesi, peripartum kardiyomiyopati şüphesinde hızlı kardiyak fonksiyon taraması, volüm durumunun kaba değerlendirmesi ve zor havayolunda anatomik işaretleme gibi amaçlarla giderek daha fazla kullanılmaktadır. AI, POCUS görüntülerinde kalite kontrolü (doğru kesit yakalama), otomatik ölçüm/segmentasyon ve klinik karar destek çıktıları ile operatör bağımlılığını azaltmayı hedefler. Bu alan; anne-fetüs güvenliği açısından yüksek potansiyel taşısa da, yanlış segmentasyon veya yanlış yorumun klinik etkisi büyük olabileceğinden “insan-onaylı” (human-in-the-loop) kullanım, güvenlik sınırları ve merkez-spesifik doğrulama esastır.^{1,21}


5. İNTRAOPERATİF HEMODİNAMİK YÖNETİMDE YZ VE OTOMASYON

5.1. Spinal hipotansiyon: öngörü ve hedefe yönelik vazopressör stratejileri

Sezaryen spinal anestezisinde hipotansiyon sık görülür ve uteroplazental perfüzyonu etkileyebilir. Uluslararası konsensus; profilaktik/erken vazopressör stratejileri ve hedef basınç yaklaşımını vurgular.²³ YZ bu alanda iki düzeyde katkı sunabilir: (i) hipotansiyon gelişmeden önce riskin tahmini (erken uyarı), (ii) vazopressör ve sıvı tedavisinin hedefte tutulmasına yardım eden otomasyon (Şekil 4; Tablo 4). Arter basınç dalga formundan hipotansiyon tahmini için geliştirilen ML tabanlı yaklaşımlar, genel anestezi popülasyonunda doğrulanmıştır.²⁴ Obstetrik olgularda ise gebelik fizyolojisine uyarlama, bradikardi-hipertansiyon güvenlik sınırları ve maternal-neonatal

sonlanımlara etkisinin prospektif çalışmalarda gösterilmesi gereklidir.²⁻³

Şekil 4. Sezaryen spinal anesteziinde hipotansiyon için kapalı döngü vazopressör kontrol şeması (hedef-ölçüm-kontrol).




5.2. Kapalı döngü (closed-loop) vazopressör ve sıvı yönetimi: kontrol prensipleri

Kapalı döngü sistemler; ölçülen değişken (örn. sistolik arter basıncı) ile hedef arasındaki farkı hesaplayarak infüzyon hızını otomatik ayarlar. Bu yaklaşım “öğrenen” bir algoritma olmak zorunda değildir; ancak YZ ile birleştirildiğinde hastaya özgü duyarlılık (fenilefrin/norepinefrin yanıtı), gecikme ve gürültü filtreleme daha iyi yönetilebilir. Obstetrik literatürde otomasyonun hipotansif yükü azaltma potansiyeline dikkat çekilmekle birlikte, klinik uygulamaya geçiş için güvenlik odaklı tasarım gereklidir.² Güvenlik için (i) “sert sınırlar” (maksimum bolus/infüzyon, bradikardi/hipertansiyon durdurma kuralları), (ii) manuel devralma (override), (iii) alarm hiyerarşisi ve (iv) olay kaydı/audit (neden-sonuç analizi) zorunludur (Tablo 4).

5.3. Jinekolojik cerrahide hemodinamik ve ventilasyon etkileşimi

Robotik/laparoskopik jinekolojik cerrahide pnömoperitoneum ve Trendelenburg; venöz dönüş, pulmoner kompliyans ve intrakraniyal/intraoküler basınç üzerinde etkiler yaratabilir. YZ destekli “dinamik risk panelleri”, ventilasyon parametreleri (plateau basıncı, driving pressure), hemodinamik değişkenler ve anestezi derinliği bir arada sunarak klinisyen için daha bütüncül bir durum farkındalığı sağlayabilir (Şekil 5). Bu yaklaşımın klinik yararı, yalnızca tahmin doğruluğu değil; karar vermeyi hızlandırma ve komplikasyon oranlarını azaltma üzerinden değerlendirilmelidir.

Şekil 5. Kişiselleştirilmiş perioperatif risk paneli örneği: PPH, hipotansiyon, PONV ve şiddetli ağrı için karar destek.



6. ANESTEZİ DERİNLİĞİ, ANALJEZİ-NOCİSEPSİYON VE SOLUNUM YÖNETİMİNDE YZ

6.1. EEG tabanlı derinlik değerlendirmesinde ML ve otomasyon

BIS gibi indeksler, EEG sinyallerinden türetilen algoritmik çıktılardır. Kapalı döngü (closed-loop) anestezi sistemleri, farklı cerrahi popülasyonlarda anestezi ajan titrasyonunu standardize etmeyi ve hedeflenen derinlikte kalma süresini artırmayı amaçlar. Obstetrik/jinekolojik alanda bu yaklaşımın uygulanabilirliği tartışılmaktadır.¹ Obstetrik/jinekolojik cerrahide (özellikle kısa süreli girişimler, sedasyon gerektiren işlemler) ML destekli derinlik izlem ve otomasyon; aşırı derin anesteziyi azaltma, hemodinamik stabiliteyi artırma ve daha hızlı derlenme potansiyeli taşır. Bununla birlikte gebelikte farmakodinamik/farmakokinetik değişkenlik ve fetal etkiler nedeniyle algoritma performansı ayrıca değerlendirilmelidir.

6.2. Nocisepsiyon indeksleri ve opioid titrasyonu

Nocisepsiyon monitörleri (örn. nabız dalgası analizi, kalp hızı değişkenliği temelli indeksler) çoğu zaman çoklu sinyalin algoritmik birleşimine dayanır. YZ ile bu sinyallerin; cerrahi uyarana yanıtı daha doğru yansıtan kişiselleştirilmiş analjezi önerilerine dönüştürülmesi hedeflenmektedir. Obstetrik alanda opioid tasarrufu önemlidir (anne uyanıklığı, emzirme, neonatal sedasyon). Bu nedenle YZ'nin öneri ürettiği her senaryoda “opioid-sparing” stratejiler, multimodal analjezi ve klinisyenin kontrolü ön planda olmalıdır (Tablo 1).

6.3. Solunum yönetimi ve ventilasyon

Jinekolojik laparoskopi/robotik cerrahide pnömoperitoneum ve Trendelenburg, mekanik ventilasyon zorluklarını artırır. Güncel ventilatörlerdeki adaptif modlar

çoğunlukla model tabanlı otomasyondur; ancak gelecekte hasta özgül akciğer mekaniği ve gaz değişimini gerçek zamanlı öğrenen YZ modelleri, PEEP ve tidal volüm titrasyonunu daha hassas hâle getirebilir. Bu alanda obstetrik spesifik kanıt sınırlı olduğundan, uygulama öncesi prospektif güvenlik çalışmaları gereklidir.

7. POSTOPERATİF DÖNEM: AĞRI, PONV, İYİLEŞME VE UZAKTAN İZLEM

7.1. Kişiselleştirilmiş ağrı tahmini ve opioid tasarrufu

Sezaryen sonrası ağrı yönetimi anne-bebek etkileşimi ve erken mobilizasyon açısından kritiktir. Spinal morfin uygulanan sezaryenlerde anlamlı ağrıyı öngörmeye yönelik ML modelleri rapor edilmiştir.²⁵ Daha geniş perioperatif popülasyonda ise ML ile akut/kronik postoperatif ağrı ve opioid kullanımını tahmin etmeye yönelik çalışmaların hızla arttığı; ancak örneklem büyüklüğü, çıktı tanımı ve dış doğrulamada değişkenlik bulunduğu vurgulanmaktadır.²⁶ Bu modeller; (i) yüksek riskli hastada erken multimodal analjezi, (ii) opioid-ilişkili yan etki riski yüksek olguda alternatif stratejiler (fasyal plan blokları, non-opioid analjezikler), (iii) taburculuk sonrası tele-izlem planı için tetikleyici olabilir (Şekil 5).

7.2. PONV tahmini ve karar destek

PONV, özellikle jinekolojik laparoskopide sık görülür ve hasta memnuniyetini belirgin etkiler. ML tabanlı PONV tahmin modellerinin geliştirildiği ve doğrulandığı çalışmalar mevcuttur.²⁷ Bu modeller, klasik risk skorlarını (örn. Apfel) dışlamadan; hasta özellikleri, anestezi tekniği, opioid dozu, cerrahi süre ve profilaksi gibi değişkenleri birleştirerek kişiselleştirilmiş antiemetik plan önerebilir. Klinik entegrasyonda “öneri”nin şeffaf biçimde sunulması (hangi

faktörlerin riski artırdığı) ve gereksiz profilaksi/ilaç etkileşimi riskinin azaltılması önemlidir.

7.3. Uzaktan izlem ve dijital sağlık entegrasyonu

Erken taburculuğun arttığı jinekolojik cerrahi ve sezaryen sonrası süreçte; mobil uygulamalar, giyilebilir sensörler ve EHR entegrasyonu ile ağrı, mobilizasyon, kanama ve hipertansiyon gibi parametrelerin izlenmesi mümkündür. YZ, bu verilerden “deteriorasyon” sinyallerini çıkararak uygun zamanda sağlık ekibini uyarabilir. Ancak yanlış alarmlar, hasta kaygısı, veri gizliliği ve eşit erişim (dijital uçurum) bu yaklaşımın temel riskleridir (Tablo 2).

8. OBSTETRİK KRİTİK BAKIM VE ACİLLERDE YZ

Obstetrik yoğun bakım gereksinimi nadir olsa da mortalite/morbidite yükü yüksektir. Obstetrik acillerde (sepsis, ağır preeklampsi/eclampsia, masif kanama) erken uyarı sistemleri ve prediktif analitik yaklaşımlar gündemdedir.³ YZ'nin potansiyel katkısı; erken bozulma tahmini, kaynak planlama ve klinik ekip koordinasyonunu hızlandırmadır. Ancak bu sistemlerin “alarm yorgunluğu” oluşturma riski vardır; bu nedenle obstetrik acil ekipleri için önceden tanımlanmış eylem protokolleriyle birlikte kullanılmalıdır (Tablo 3).

9. ETİK, HUKUKİ VE REGÜLATİF ÇERÇEVE; GÜVENLİ UYGULAMAYA GEÇİŞ

9.1. Etik ilkeler, veri gizliliği ve önyargı (bias)

WHO, üretken YZ ve büyük multimodal modeller dâhil olmak üzere sağlıkta YZ için şeffaflık, insan gözetimi, kapsayıcılık, güvenlik, sorumluluk ve veri mahremiyeti gibi

ilkeleri vurgulamaktadır.⁵ Özellikle gebelikte; (i) hassas veriler (üreme sağlığı, genetik), (ii) yüz görüntüsü gibi biyometrik veriler ve (iii) iki bireyi etkileyen kararlar söz konusu olduğundan etik değerlendirme daha da kritik hâle gelir. Modelin belirli alt gruplarda (obezite, farklı etnik kökenler, komorbidite yükü yüksek hastalar) daha düşük performans göstermesi, eşitsizliği artırabilir. Bu nedenle yerel doğrulama, alt grup analizleri ve sürekli performans izlemi zorunludur.

9.2. Kanıt üretimi ve raporlama standartları

Klinik tahmin modellerinin raporlanması için TRIPOD+AI, risk of bias değerlendirmesi için PROBAST+AI; yapay zekâ içeren klinik çalışma protokolleri ve raporları için SPIRIT-AI ve CONSORT-AI; erken klinik uygulama değerlendirmesi için DECIDE-AI önerilmektedir (Tablo 2).⁶⁻¹⁰ Obstetrik/jinekolojik anestezide AI çalışmaları planlanırken, maternal ve neonatal sonuçlarının birlikte raporlanması, güvenlik olaylarının (hipotansiyon yükü, fetal asidoz, kanama, ilaç hatası) standart tanımlarla verilmesi ve klinik iş akışına entegrasyonun (EHR içine gömülme, uyarı düzeyi, devralma) açıkça tanımlanması gerekir.

9.3. Regülasyon ve yaşam döngüsü yönetimi

EU AI Act, belirli kullanım alanları için risk temelli bir düzenleyici çerçeve getirerek “yüksek riskli” sistemlerde daha sıkı yükümlülükler tanımlamıştır.²⁸ ABD FDA, AI-etkin cihaz yazılım işlevlerinde planlı güncellemeleri güvenli biçimde yönetmek için Predetermined Change Control Plan (PCCP) yaklaşımına yönelik rehber yayımlamıştır.²⁹ Ayrıca NIST AI Risk Management Framework (AI RMF 1.0), AI risklerinin yaşam döngüsü boyunca (tasarım-geliştirme-dağıtım-izlem) yönetilmesine yönelik gönüllü bir çerçeve sunar.³⁰ Bu düzenleyici/etik çerçeveler, obstetrik anestezide kullanılacak herhangi bir AI aracının; veri güvenliği, klinik performans,

izlenebilirlik ve güncelleme yönetimi açısından kurumsal yönetim altında olmasını gerektirir (Şekil 2).

9.4. Klinik entegrasyon için pratik yol haritası

Klinik uygulamaya geçişte önerilen adımlar şunlardır: (i) klinik problem tanımı ve eylem protokolü (alarm geldiğinde ne yapılacak?), (ii) veri kaynaklarının envanteri ve kalite kontrolü, (iii) model geliştirme + dış doğrulama, (iv) kullanıcı testleri (human factors), (v) pilot uygulama ve prospektif etki değerlendirmesi, (vi) dağıtım sonrası performans izleme ve drift yönetimi. Bu süreçte obstetrik ekip (kadın-doğum, neonatoloji, anesteziyoloji, hemşire-ebe), veri bilimi ve hastane bilişim birimi birlikte çalışmalıdır (Tablo 2).

10. GELECEK PERSPEKTİFİ: MULTİMODAL MODELLER, FEDERATED LEARNING, “MATERNAL-FETÜS DİJİTAL İKİZİ” VE ÜRETKEN YZ

Üretken YZ'nin sağlıkta kullanımına ilişkin WHO rehberi, büyük multimodal modellerin potansiyel faydalarını ve risklerini (yanlılık, güvenlik, gizlilik, sorumluluk) ayrıntılı olarak ele almıştır.⁵ Obstetrik/jinekolojik anesteziye gelecek yönelimler; EHR + dalga formu + ultrason + laboratuvarı birleştiren multimodal “temel modeller”, kurumlar arası veri paylaşmadan öğrenmeyi sağlayan federated learning, kişiye özgü simülasyonlarla “maternal-fetüs dijital ikizi” kavramı ve klinisyen için güvenli “YZ asistanı” arayüzleridir.³ Bu yaklaşımlar; özellikle nadir olaylarda (masif kanama, yüksek blok) erken sinyal yakalama, eğitim/simülasyon ve kalite iyileştirme alanlarında çarpan etkisi yaratabilir. Üretken YZ'nin perioperatif dokümantasyon ve raporlamada kullanımı, zaman tasarrufu sağlayabilir; ancak kaynak atfı, hatalı içerik üretimi ve

mahremiyet riskleri nedeniyle “insan onayı” ve güvenlik katmanları ile uygulanmalıdır.⁴

11. SONUÇ

YZ, obstetrik ve jinekolojik anesteziye risk stratifikasyonu, prosedürel yardım (neuraksiyal ultrason), hemodinamik optimizasyon, postoperatif iyileşme ve dokümantasyon gibi birçok başlıkta güçlü fırsatlar sunmaktadır. Bununla birlikte klinik faydanın sürdürülebilir olması; metodolojik standartlara uygun geliştirme, çok merkezli dış doğrulama, insan gözetimi, etik-hukuki uyum ve yaşam döngüsü izlemine bağlıdır. En iyi yaklaşım; YZ’yi kılavuz-temelli klinik akıl yürütmeyi güçlendiren, şeffaf ve güvenli bir “ekip üyesi” olarak konumlandırmaktır.

ANAHTAR NOKTALAR

- Obstetrik/jinekolojik anesteziye YZ’nin en güçlü kullanım alanları: risk stratifikasyonu, neuraksiyal/POCUS ultrason desteği, hemodinamik optimizasyon ve postoperatif iyileşme-dokümantasyondur.
- Yüksek doğruluk tek başına yeterli değildir; kalibrasyon, yanlış alarm yükü, klinik yarar ve gerçek iş akışına entegrasyon birlikte değerlendirilmelidir.
- Gebe popülasyonunda fizyolojik değişkenlik, nadir olayların azlığı ve önyargı/drift riski nedeniyle çok merkezli doğrulama ve sürekli izlem kritik önemdedir.
- Üretken YZ (LLM/LMM) klinik özetleme ve dokümantasyonda zaman kazandırabilir; ancak

hallucination ve gizlilik riskleri nedeniyle “insan onayı” şarttır.

- Güvenli uygulama için RIPOD + AI/PROBAST + AI/SPIRIT - AI/CONSORT - AI/DECIDE - AI gibi standartlar ve risk temelli yönetim çerçeveleri (EU AI Act, FDA PCCP, NIST AI RMF) birlikte kullanılmalıdır.

KAYNAKLAR

1. Kong, A. Y. H., Liu, N., Tan, H. S., Sia, A. T. H., & Sng, B. L. (2025). Artificial intelligence in obstetric anaesthesiology - the future of patient care?. *International journal of obstetric anaesthesia*, 61, 104288. <https://doi.org/10.1016/j.ijoa.2024.104288>.
2. Frassanito, L., Filetici, N., Raimondo, P., Malvasi, A., Gaudio, A., Peragine, A., Lombardi, F., Vassalli, F., Pasta, G., & Bignami, E. G. (2026). Anesthesia for cesarean delivery in the era of artificial intelligence: a narrative review. *Journal of anesthesia, analgesia and critical care*, 6(1), 19. <https://doi.org/10.1186/s44158-025-00326-y>.
3. Kovacheva, V. P., & Burns, M. L. (2026). Artificial intelligence and predictive analytics in obstetric anesthesia: early warning for maternal complications. *Current opinion in anaesthesiology*, 10.1097/ACO.0000000000001613. Advance online publication. <https://doi.org/10.1097/ACO.0000000000001613>.
4. Julius, A., & Bowness, J. S. (2025). Generative AI models: the next anaesthetic agent?. *British journal of anaesthesia*, 135(1), 21–25. <https://doi.org/10.1016/j.bja.2025.04.004>.
5. Ethics and governance of artificial intelligence for health. Guidance on large multi-modal models. Geneva: World Health Organization; 2024. Licence: CC BY-NC-SA 3.0 IGO.
6. Collins, G. S., Moons, K. G. M., Dhiman, P., Riley, R. D., Beam, A. L., Van Calster, B., Ghassemi, M., Liu, X., Reitsma, J. B., van Smeden, M., Boulesteix, A. L., Camaradou, J. C., Celi, L. A., Denaxas, S., Denniston,

- A. K., Glocker, B., Golub, R. M., Harvey, H., Heinze, G., Hoffman, M. M., ... Logullo, P. (2024). TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ (Clinical research ed.)*, 385, e078378. <https://doi.org/10.1136/bmj-2023-078378>.
7. Moons, K. G. M., Damen, J. A. A., Kaul, T., Hooft, L., Andaur Navarro, C., Dhiman, P., Beam, A. L., Van Calster, B., Celi, L. A., Denaxas, S., Denniston, A. K., Ghassemi, M., Heinze, G., Kengne, A. P., Maier-Hein, L., Liu, X., Logullo, P., McCradden, M. D., Liu, N., Oakden-Rayner, L., ... van Smeden, M. (2025). PROBAST+AI: an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. *BMJ (Clinical research ed.)*, 388, e082505. <https://doi.org/10.1136/bmj-2024-082505>.
8. Rivera, S. C., Liu, X., Chan, A. W., Denniston, A. K., Calvert, M. J., & SPIRIT-AI and CONSORT-AI Working Group (2020). Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI Extension. *BMJ (Clinical research ed.)*, 370, m3210. <https://doi.org/10.1136/bmj.m3210>.
9. Liu, X., Rivera, S. C., Moher, D., Calvert, M. J., Denniston, A. K., & SPIRIT-AI and CONSORT-AI Working Group (2020). Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI Extension. *BMJ (Clinical research ed.)*, 370, m3164. <https://doi.org/10.1136/bmj.m3164>.
10. Vasey, B., Nagendran, M., Campbell, B., Clifton, D. A., Collins, G. S., Denaxas, S., Denniston, A. K., Faes, L., Geerts, B., Ibrahim, M., Liu, X., Mateen, B. A., Mathur, P., McCradden, M. D., Morgan, L., Ordish, J., Rogers,

- C., Saria, S., Ting, D. S. W., Watkinson, P., ... DECIDE-AI expert group (2022). Reporting guideline for the early-stage clinical evaluation of decision support systems driven by artificial intelligence: DECIDE-AI. *Nature medicine*, 28(5), 924–933. <https://doi.org/10.1038/s41591-022-01772-9>.
11. Wakefield, B. M., Zapf, M. A., & Ende, H. B. (2025). Artificial intelligence in prediction of postpartum hemorrhage: a primer and review. *International journal of obstetric anesthesia*, 63, 104694. <https://doi.org/10.1016/j.ijoa.2025.104694>.
 12. Ende, H. B., Domenico, H. J., Polic, A., Wesoloski, A., Zuckerwise, L. C., Mccoy, A. B., Woytash, A. R., Moore, R. P., & Byrne, D. W. (2024). Development and Validation of an Automated, Real-Time Predictive Model for Postpartum Hemorrhage. *Obstetrics and gynecology*, 144(1), 109–117. <https://doi.org/10.1097/AOG.0000000000005600>.
 13. Lengerich, B. J., Caruana, R., Painter, I., Weeks, W. B., Sitcov, K., & Souter, V. (2024). Interpretable machine learning predicts postpartum hemorrhage with severe maternal morbidity in a lower-risk laboring obstetric population. *American journal of obstetrics & gynecology MFM*, 6(8), 101391. <https://doi.org/10.1016/j.ajogmf.2024.101391>.
 14. Westcott, J. M., Hughes, F., Liu, W., Grivainis, M., Hoskins, I., & Fenyo, D. (2022). Prediction of Maternal Hemorrhage Using Machine Learning: Retrospective Cohort Study. *Journal of medical Internet research*, 24(7), e34108. <https://doi.org/10.2196/34108>.
 15. Bernstorff, M., Vistisen, S. T., & Enevoldsen, K. C. (2024). Natural language processing for electronic health records in anaesthesiology: an introduction to clinicians with recommendations and pitfalls. *Journal of clinical*

- monitoring and computing*, 38(2), 241–245.
<https://doi.org/10.1007/s10877-024-01128-3>.
16. Yoon, S. B., Lee, J., Lee, H. C., Jung, C. W., & Lee, H. (2024). Comparison of NLP machine learning models with human physicians for ASA Physical Status classification. *NPJ digital medicine*, 7(1), 259.
<https://doi.org/10.1038/s41746-024-01259-6>.
 17. Mushambi, M. C., Kinsella, S. M., Popat, M., Swales, H., Ramaswamy, K. K., Winton, A. L., Quinn, A. C., Obstetric Anaesthetists' Association, & Difficult Airway Society (2015). Obstetric Anaesthetists' Association and Difficult Airway Society guidelines for the management of difficult and failed tracheal intubation in obstetrics. *Anaesthesia*, 70(11), 1286–1306.
<https://doi.org/10.1111/anae.13260>.
 18. Xia, M., Jin, C., Zheng, Y., Wang, J., Zhao, M., Cao, S., Xu, T., Pei, B., Irwin, M. G., Lin, Z., & Jiang, H. (2024). Deep learning-based facial analysis for predicting difficult videolaryngoscopy: a feasibility study. *Anaesthesia*, 79(4), 399–409.
<https://doi.org/10.1111/anae.16194>.
 19. Apfelbaum, J. L., Hagberg, C. A., Connis, R. T., Abdelmalak, B. B., Agarkar, M., Dutton, R. P., Fiadjoe, J. E., Greif, R., Klock, P. A., Mercier, D., Myatra, S. N., O'Sullivan, E. P., Rosenblatt, W. H., Sorbello, M., & Tung, A. (2022). 2022 American Society of Anesthesiologists Practice Guidelines for Management of the Difficult Airway. *Anesthesiology*, 136(1), 31–81.
<https://doi.org/10.1097/ALN.0000000000004002>.
 20. Kamimura, Y., Yamamoto, N., Shiroshita, A., Miura, T., Tsuji, T., Someko, H., Imai, E., Kimura, R., & Sobue, K. (2024). Comparative efficacy of ultrasound guidance or conventional anatomical landmarks for neuraxial puncture in adult patients: a systematic review and

- network meta-analysis. *British journal of anaesthesia*, 132(5), 1097–1111.
<https://doi.org/10.1016/j.bja.2023.09.006>.
21. Bowness, J. S., Metcalfe, D., El-Boghdadly, K., Thurley, N., Morecroft, M., Hartley, T., Krawczyk, J., Noble, J. A., & Higham, H. (2024). Artificial intelligence for ultrasound scanning in regional anaesthesia: a scoping review of the evidence from multiple disciplines. *British journal of anaesthesia*, 132(5), 1049–1062.
<https://doi.org/10.1016/j.bja.2024.01.036>.
22. National Institute for Health and Care Excellence. (2021, January 26). *Accuro for guiding epidural or spinal anaesthesia*(Medtech innovation briefing MIB245). <https://www.nice.org.uk/guidance/mib245>.
23. Kinsella, S. M., Carvalho, B., Dyer, R. A., Fernando, R., McDonnell, N., Mercier, F. J., Palanisamy, A., Sia, A. T. H., Van de Velde, M., Vercueil, A., & Consensus Statement Collaborators (2018). International consensus statement on the management of hypotension with vasopressors during caesarean section under spinal anaesthesia. *Anaesthesia*, 73(1), 71–92.
<https://doi.org/10.1111/anae.14080>.
24. Hatib, F., Jian, Z., Buddi, S., Lee, C., Settels, J., Sibert, K., Rinehart, J., & Cannesson, M. (2018). Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis. *Anesthesiology*, 129(4), 663–674.
<https://doi.org/10.1097/ALN.0000000000002300>.
25. Tan, C. W., Koh, J. Z., Jin, H., Han, N. R., Cheng, S. M., Ta, A. W. A., Goh, H. L., & Sng, B. L. (2024). Machine learning approach to predict postoperative pain after spinal morphine administration during caesarean delivery. *Heliyon*, 10(23), e40602.
<https://doi.org/10.1016/j.heliyon.2024.e40602>.

26. Langford, D. J., Reichel, J. F., Zhong, H., Basseri, B. H., Koch, M. P., Kolady, R., Liu, J., Sideris, A., Dworkin, R. H., Poeran, J., & Wu, C. L. (2025). Machine learning research methods to predict postoperative pain and opioid use: a narrative review. *Regional anesthesia and pain medicine*, 50(2), 102–109. <https://doi.org/10.1136/rapm-2024-105603>.
27. Glebov, M., Lazebnik, T., Katsin, M., Orkin, B., Berkenstadt, H., & Bunimovich-Mendrazitsky, S. (2025). Predicting postoperative nausea and vomiting using machine learning: a model development and validation study. *BMC anesthesiology*, 25(1), 135. <https://doi.org/10.1186/s12871-025-02987-2>.
28. European Parliament and Council of the European Union. (2024, July 12). *Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act)*. EUR-Lex. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32024R1689>.
29. U.S. Food and Drug Administration. (2025, August 18). *Marketing submission recommendations for a predetermined change control plan for artificial intelligence-enabled device software functions: Guidance for industry and Food and Drug Administration staff*. U.S. Department of Health and Human Services. <https://www.fda.gov/media/166704/download>
30. National Institute of Standards and Technology. (2023). *Artificial Intelligence Risk Management Framework (AI RMF 1.0)* (NIST AI 100-1). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.AI.100-1>.

ADNEKSİYEL KİTLELERİN YÖNETİMDE YAPAY ZEKA KULLANIMI

Oğuzhan KARAKOÇ¹

1. GİRİŞ

Adneksiyel kitleler, jinekolojik pratiğin hem sık görülen hem de yönetimi en fazla tartışma yaratan klinik sorunlarından biridir. Özellikle üreme çağındaki ve peri/postmenopozal dönemdeki hastalarda, benign ve malign lezyonların birbirinden güvenilir şekilde ayrılması hem hasta prognozu hem de sağlık sistemi kaynaklarının etkin kullanımı açısından kritik öneme sahiptir. Günlük pratikte çoğu adneksiyel kitle iyi huylu olmakla birlikte, over kanseri olasılığının göz ardı edilmemesi gerekmektedir(Vázquez-Manjarrez et al., 2020).

Klasik yaklaşım, klinik öykü, fizik muayene, tümör belirteçleri ve başta transvajinal ultrasonografi olmak üzere görüntüleme yöntemlerinin bir arada değerlendirilmesine dayanır(Padival et al., 2025). Bununla birlikte, operatif karara giden süreçte hem aşırı tedavi (gereksiz cerrahi) hem de yetersiz tedavi (maligniteyi atlama) riski halen önemli bir sorun olmaya devam etmektedir. Özellikle düşük prevelanslı hasta gruplarında, tek bir klinik veya görüntüleme parametresine dayanarak yüksek doğrulukta risk sınıflaması yapmak çoğu zaman mümkün olmamaktadır.

Son yıllarda yapay zekâ, makine öğrenmesi ve derin öğrenme tabanlı yöntemler, tıbbi görüntülemenin pek çok

¹ Op. Dr., Bandırma Eğitim ve Araştırma Hastanesi Kadın Hastalıkları ve Doğum Kliniği, ORCID: 0000-0001-7918-4524.

alanında olduğu gibi adneksiyel kitle değerlendirmesinde de giderek daha fazla gündeme gelmektedir. Yapay zekâ algoritmaları; ultrason, bilgisayarlı tomografi ve manyetik rezonans görüntüleri üzerinden karmaşık morfolojik ve fonksiyonel özellikleri insan gözünün ötesinde bir ayrıntı düzeyinde analiz edebilme potansiyeline sahiptir. Bu sayede malignite risk tahmini, kitlelerin sınıflandırılması ve cerrahi planlamaya yönelik karar destek sistemlerinin geliştirilmesi mümkün hale gelmektedir(Ardakani et al., 2025).

Bu bölümde adneksiyel kitlelere ilişkin klasik klinik ve görüntüleme yaklaşımı özetlendikten sonra, yapay zekânın temel kavramları ve tıbbi görüntülemedeki yeri kısaca ele alınacak; ardından adneksiyel kitlelerde yapay zekâ uygulamalarına ilişkin güncel literatür, model performansları, klinik entegrasyon olanakları ve sınırlılıkları tartışılacaktır. Amaç, kadın hastalıkları ve doğum pratiğinde adneksiyel kitle yönetimi ile ilgilenen klinisyenlere, yapay zekâ temelli karar destek araçlarının mevcut durumunu ve yakın gelecekteki olası katkılarını, pratik ve eleştirel bir bakış açısıyla sunmaktır. Böylece okuyucunun, kendi hasta popülasyonunda hangi klinik sorular için yapay zekâdan yararlanabileceğini ve mevcut modellerin hangi noktalarda dikkatle yorumlanması gerektiğini daha net biçimde kavrayabilmesi hedeflenmektedir.

2. ADNEKSİYEL KİTLELERE GENEL BAKIŞ

2.1. Tanım ve sınıflandırma

Adneksiyel kitleler; over, tubalar, peritoneal yüzeyler veya geniş bağ dokusu kökenli olup pelvik ultrasonografide kitle görünümü veren tüm lezyonları kapsayan geniş bir tanımdır(Yoeli-Bik et al., 2025). Klinik değerlendirmede öncelikle kitlelerin kökeni, içeriği ve morfolojik özellikleri belirlenmeye çalışılır. Bu nedenle sınıflandırma hem tanı koyma

sürecini standartlaştırmak hem de malignite riskini öngörmek açısından önemli bir basamaktır(Almeida et al., 2025).

En temel yaklaşım, adneksiyel kitleleri basit (uniloküler) kistler, kompleks kistler, solid lezyonlar ve solid-kistik yapılar şeklinde morfolojik özelliklere göre sınıflandırmaktır. Basit kistler çoğunlukla iyi huyludur ve hormonal kaynaklı işlevsel yapılardır. Kompleks yapılar ise septasyon, papiller projeksiyon veya ekojen komponentler içerdiğinden malignite açısından daha dikkatli değerlendirilmelidir(Moro, Vagni, et al., 2025).

Uluslararası sınıflandırmalarda, özellikle IOTA grubunun tanımladığı terminoloji ve tanısal kriterler yaygın olarak kullanılmaktadır. Bu kriterler; duvar yapısı, iç yüzey düzensizlikleri, solid alanlar, Doppler akımı ve ek bulgular gibi çok sayıda parametrenin sistematik değerlendirilmesini sağlar(Timmerman et al., 2010). Böylece klinik karar sürecinde hem gözlemciler arası uyum artmakta hem de risk değerlendirmesi daha nesnel hale gelmektedir.

2.2. Epidemiyoloji

Adneksiyel kitleler kadınların yaşam boyu herhangi bir döneminde karşılaşılabileceği yaygın klinik oluşumlardır. Üreme çağındaki kadınlarda görülme sıklığı yüksektir ve çoğunlukla fonksiyonel veya benign karakterdedir(Wheeler et al., 2023). Perimenopozal ve postmenopozal dönemde ise malignite olasılığı artmakta, bu da doğru risk sınıflamasını daha kritik hale getirmektedir(Davenport et al., 2022).

Toplum temelli çalışmalarda, pelvik ultrasonografi taramalarında adneksiyel kitle saptanma oranı yaş gruplarına göre değişmekle birlikte yüzde 5 ile 20 arasında bildirilmiştir. Özellikle basit kistler, premenopozal dönemde en sık görülen lezyon tipidir ve çoğu birkaç takip muayenesi içinde gerileme eğilimi göstermektedir. Kompleks morfolojiye sahip lezyonlar ise

daha düşük oranda görülmekle birlikte malignite açısından daha yüksek dikkat gerektirir(Erdodi et al., 2025).

Ovaryan kanser insidansı genel popülasyonda düşük olmasına rağmen mortalitesi yüksek bir hastalıktır. Bu nedenle adneksiyel kitlelerin doğru yönetimi, gereksiz cerrahilerin önlenmesi kadar malign olguların erken tanısı açısından da önemli bir halk sağlığı ihtiyacını karşılamaktadır(Jiang et al., 2025).

2.3. Klinik yaklaşımın temel prensipleri

Adneksiyel kitlelerin yönetiminde temel amaç, malignite riskini doğru şekilde değerlendirmek ve hastaya en uygun tedavi stratejisini belirlemektir. Klinik yaklaşım genellikle ayrıntılı öykü, fizik muayene, tümör belirteçleri ve görüntüleme bulgularının birlikte yorumlanmasına dayanır. Özellikle hastanın yaşı, menopoz durumu, semptomların süresi ve eşlik eden risk faktörleri doğru risk sınıflaması açısından önem taşır(Kaijser, 2015).

Transvajinal ultrasonografi, adneksiyel kitlelerin ilk basamak değerlendirmesinde altın standart yöntem olarak kabul edilir. Morfolojik özellikler, kitle içeriği, duvar yapısı, papiller çıkıntılar ve solid bileşenlerin varlığı klinisyenin risk değerlendirmesinde belirleyicidir. Gerekli durumlarda Doppler inceleme ek bilgiler sağlar; ancak tek başına tanısal karar için yeterli değildir. Ultrason bulgularının deneyime bağlı değişkenlik göstermesi nedeniyle, değerlendirmede standart terminoloji ve yapılandırılmış raporlama sistemleri tercih edilmelidir.

Laboratuvar testleri arasında CA-125 başta olmak üzere bazı tümör belirteçleri yardımcı olabilir; ancak benign durumlarda da yükselebileceğinden tek başına karar vermeyi desteklemez. Bu nedenle klinik bulgular, tümör belirteçleri ve görüntüleme sonuçları birlikte yorumlanarak olgunun düşük, orta

veya yüksek risk kategorisine yerleştirilmesi önerilir(Andreotti et al., 2020).

Risk sınıflandırmasının ardından, takip, medikal tedavi veya cerrahi seçenekleri hastanın yaşı, fertilité beklentisi ve klinik risk düzeyine göre bireyselleştirilmelidir. Böylece gereksiz girişimler azaltılırken potansiyel malign olguların da gecikmeden doğru merkeze yönlendirilmesi sağlanır.

3. GÖRÜNTÜLEME YÖNTEMLERİNDE ADNEKSİYEL KİTLE DEĞERLENDİRMESİ

3.1. Ultrasonografi

Transvajinal ultrasonografi, adneksiyel kitlelerin değerlendirilmesinde ilk basamak ve en değerli görüntüleme yöntemidir. Yüksek çözünürlüklü görüntü elde etme, pelvik organlara yakın temas sayesinde detaylı inceleme yapabilme ve gerçek zamanlı değerlendirme imkânı, bu yöntemi hem tanısal doğruluk hem de pratik uygulanabilirlik açısından öne çıkarır. Ayrıca radyasyon içermemesi, erişilebilir olması ve maliyet etkinliği nedeniyle adneksiyel kitle yönetiminde standart tanısal yaklaşımın temelini oluşturur(L. Liu et al., 2024).

Ultrason değerlendirmesinde kitlelerin morfolojik özellikleri büyük önem taşır. Kitle duvarının kalınlığı, iç yüzey düzeni, septasyon varlığı, papiller çıkıntılar, solid alanlar ve iç ekojenite, malignite riskinin belirlenmesinde kritik rol oynar. Basit, ince duvarlı, unilöküler kistler genellikle iyi huylu kabul edilirken; düzensiz konturlu, kompleks yapılı veya solid komponent içeren kitlelerde malignite olasılığı artar. Bu nedenle ultrason bulgularının sistematik olarak yorumlanması gerekir.

Gözlemciler arası değişkenliği azaltmak amacıyla uluslararası gruplar tarafından önerilen yapılandırılmış değerlendirme kriterleri önem kazanmıştır. Özellikle IOTA

terminolojisi ve değerlendirme modelleri, morfolojik bulguların standardize edilmesini sağlayarak hem deneyimli hem de deneyimsiz klinisyenler için daha tutarlı sonuçlar elde edilmesine katkıda bulunur. Bu yapılandırılmış yaklaşım, risk sınıflamasının daha objektif yapılmasını ve hastaların uygun tedavi seçeneklerine daha doğru yönlendirilmesini sağlar(Sayasneh et al., 2013).

3.2. Doppler bulguları

Doppler ultrasonografi, adneksiyel kitlelerin vaskülaritesini değerlendirmek için kullanılan tamamlayıcı bir yöntemdir. Kan akımının varlığı, akım paternleri ve damar dağılımı gibi özellikler, malignite olasılığı açısından önemli ipuçları sağlayabilir. Özellikle solid komponent veya papiller çıkıntı içeren lezyonlarda Doppler inceleme, bu yapıların neoanjiyogenez ile ilişkili artmış vaskülarite gösterip göstermediğini değerlendirmek amacıyla kullanılır(Moro, Momi, et al., 2025).

Genel olarak, düşük dirençli akım paternleri ve periferik ya da merkezi belirgin kanlanma malignite lehine bulunabilir; ancak bu bulgular tek başına tanı koydurucu değildir. Çünkü bazı benign lezyonlar da benzer kan akım özellikleri gösterebilir. Bu nedenle Doppler değerlendirmesi, morfolojik ultrason bulgularının tamamlayıcısı olarak yorumlanmalı ve karar süreci yalnızca Doppler parametrelerine dayandırılmamalıdır.

Doppler tekniğinin en önemli sınırlılıklarından biri, operatör deneyimine bağlı değişkenlik göstermesi ve farklı cihazlarda akım parametrelerinin standart olmamasıdır. Bu nedenle Doppler sonuçları her zaman klinik bağlam ve diğer görüntüleme bulguları ile bütüncül olarak değerlendirilmelidir.

3.3. BT ve MRI'nin yeri

Bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRI), adneksiyel kitlelerin değerlendirilmesinde ultrasonografinin yetersiz kaldığı durumlarda başvuru alan ileri görüntüleme yöntemleridir. BT genellikle akut batın, komplikasyon şüphesi veya pelvik kitlelerin abdominal yayılımını değerlendirmek amacıyla tercih edilir. Malignite olasılığı bulunan olgularda, özellikle üst batın tutulumunun araştırılmasında önemli bilgiler sunar(D. G. Mitchell et al., 2013).

MRI ise yumuşak doku kontrastının yüksek olması nedeniyle adneksiyel kitlelerin karakterizasyonunda ultrasona en güçlü tamamlayıcı yöntemlerdir. Kitle içeriğinin ayrıntılı değerlendirilmesi, hemorajik kistler, dermoid kistler veya endometriomalar gibi spesifik lezyonların daha net tanınması MRI ile mümkündür. Ayrıca benign ve malign süreçlerin ayırt edilmesine yardımcı olan doku sinyal özellikleri MRI'nın önemli avantajlarından(Jeong et al., 2000).

Bununla birlikte BT ve MRI'nın rutin tarama amacıyla kullanılması önerilmez. Bu yöntemler daha çok seçilmiş olgularda, ultrason bulgularının yetersiz olduğu veya malignite riskinin daha detaylı değerlendirilmesi gereken durumlarda devreye girer.

3.4. Mevcut risk skorları (IOTA, ADNEX vb.)

Adneksiyel kitlelerde malignite riskinin doğru değerlendirilmesi, tanısal yaklaşımın en kritik aşamalarından biridir. Bu amaçla uluslararası gruplar tarafından geliştirilen çeşitli risk modelleri, klinik parametreler ve ultrason bulgularını bir araya getirerek objektif bir değerlendirme sunmayı hedefler. Bu modeller arasında en yaygın kullanılanlar IOTA kuralları ve ADNEX modeli olup birçok çalışmada güvenilirlikleri gösterilmiştir(Chankrachang et al., 2025).

IOTA Simple Rules, kitle morfolojisine ilişkin belirli özellikleri “benign lehine” ve “malign lehine” olmak üzere sınıflandırır. Papiller çıkıntı, düzensiz duvar, yoğun vaskülarite gibi malign bulguların yanı sıra ince duvarlı, uniloküler yapı gibi benign göstergeleri de içerir. Bu yapılandırılmış yaklaşım, gözlemci bağımlılığını azaltarak değerlendirmeyi daha standart hale getirir(Kaijser et al., 2013).

ADNEX modeli ise yaş, CA-125 düzeyi, görüntüleme bulguları ve merkezin referans yapısı gibi parametreleri bir arada kullanarak malignite riskini kantitatif olarak hesaplar. Modelin benign, borderline, primer invaziv ve metastatik tümör ayırımında yüksek doğruluk oranlarına ulaştığı gösterilmiştir(Hiett et al., 2022).

Bu risk skorları klinisyene tek başına tanı koydurmasa da, cerrahi planlama ve yönlendirme süreçlerinde önemli bir karar destek aracı olarak kullanılmaktadır.

4. YAPAY ZEKÂ VE TIBBİ GÖRÜNTÜLEME

4.1. Yapay zekâ temelleri (ML, DL, CNN vb.)

Yapay zekâ, bilgisayarların insan benzeri öğrenme ve problem çözme süreçlerini taklit eden algoritmalar geliştirmesini amaçlayan geniş bir bilim alanıdır. Tıpta kullanılan yapay zekâ uygulamalarının önemli bir bölümü makine öğrenmesi ve derin öğrenme temelli modellerden oluşur. Makine öğrenmesi, veriler arasındaki ilişkileri istatistiksel yöntemlerle öğrenen ve bu bilgiyle yeni verileri sınıflandırabilen algoritmaları kapsar. Denetimli, denetimsiz ve yarı denetimli öğrenme gibi alt türleri bulunur(Singh et al., 2025).

Derin öğrenme ise makine öğrenmesinin daha gelişmiş bir alt dalıdır ve çok katmanlı yapay sinir ağları kullanarak karmaşık örüntüleri yüksek doğrulukla analiz edebilir. Bu ağlar, özellikle

büyük veri setlerinin bulunduğu görüntüleme alanlarında önemli avantaj sağlar. Birden fazla katmandan oluşan bu yapılar, veriyi her aşamada daha soyut özelliklere dönüştürerek modelin daha iyi genelleme yapabilmesine olanak tanır.

Tıbbi görüntülemede en sık kullanılan derin öğrenme mimarisi konvolüsyonel sinir ağlarıdır (CNN). CNN'ler görüntüdeki kenar, doku, yapı ve morfolojik detayları otomatik olarak çıkarabilen filtrelerle çalışır. Bu nedenle ultrason, BT ve MRI gibi görüntülerin analizinde yüksek doğruluk ve hız sağlar(X. Liu et al., 2019).

Adneksiyel kitlelerin değerlendirilmesinde CNN tabanlı modeller; kitle morfolojisini tanıma, malignite riskini tahmin etme ve görüntüdeki kritik alanları belirleme gibi görevlerde geleneksel yöntemlere kıyasla daha istikrarlı performans gösterebilmektedir. Bu özellikleri, derin öğrenmeyi kadın hastalıkları görüntüleme pratiğinde giderek daha cazip hale getirmektedir.

4.2. Kadın doğum pratiğinde yapay zekâ uygulamaları

Yapay zekâ teknolojileri, kadın hastalıkları ve doğum alanında son yıllarda hızla yaygınlaşan bir kullanım alanı bulmuştur. Özellikle görüntüleme verilerinin yoğun olduğu obstetrik ve jinekolojik uygulamalarda, yapay zekâ destekli modeller tanısal doğruluğu artırma, gözlemciden kaynaklanan değişkenliği azaltma ve klinik kararları daha tutarlı hale getirme potansiyeli taşımaktadır. Obstetride, fetal biyometri ölçümlerinin otomatik yapılması, anomali taramalarında görüntü optimizasyonu ve doğum eylemi öngörüsü gibi alanlarda yapay zekâdan yararlanılmaktadır. Bu modeller, hem deneyimli hem de deneyimsiz uygulayıcılarda ölçüm hatalarını azaltarak daha güvenilir sonuçlar elde edilmesine olanak sağlar(Venturini et al., 2025).

Jinekoloji alanında ise ultrason görüntülerinin otomatik yorumlanması, endometriyal patolojilerin sınıflandırılması, servikal sitoloji analizlerinde hata oranının düşürülmesi ve malignite risk tahmininde yapay zekâ temelli karar destek sistemlerinin geliştirilmesi üzerine yoğun çalışmalar yapılmaktadır. Derin öğrenme mimarileri, özellikle morfolojik karmaşıklığı yüksek olan görüntülerde hem tanı koyma sürecini hızlandırmakta hem de ince ayrıntıların atlanmasını engellemektedir.

Buna ek olarak, minimal invaziv cerrahide görüntü destekli navigasyon, kritik anatomik yapıların otomatik tanınması ve operasyon sırasında gerçek zamanlı rehberlik sağlayan sistemlerin geliştirilmesi de yapay zekânın giderek daha fazla ilgi gördüğü alanlar arasında yer almaktadır. Bu teknolojilerin, klinik pratikte yaygınlaşmasıyla birlikte hasta güvenliği ve tedavi etkinliği açısından önemli kazanımlar elde edilmesi beklenmektedir.

4.3. Veri setleri, etiketleme ve eğitim süreçleri

Yapay zekâ modellerinin güvenilir ve klinik olarak anlamlı sonuçlar üretebilmesi için, yüksek kaliteli ve yeterli büyüklükte veri setlerine ihtiyaç vardır. Tıbbi görüntüleme alanında kullanılan veri setleri genellikle ultrason, BT veya MRI görüntülerinden oluşur ve her bir görüntünün doğru şekilde etiketlenmesi model performansının temel belirleyicisidir. Etiketleme; kitle sınırının belirlenmesi, morfolojik özelliklerin tanımlanması veya malignite durumunun doğrulanması gibi görevleri içerir. Bu süreçte radyolog ve jinekologların iş birliği önemlidir, çünkü yanlış veya tutarsız etiketleme modelin tüm öğrenme sürecini olumsuz etkileyebilir(Zhang & Nie, 2022).

Veri setlerinin çeşitliliği de modelin genellenebilirliği açısından kritik bir unsurdur. Farklı cihazlardan, farklı merkezlerden ve farklı hasta popülasyonlarından elde edilmiş

görüntüler içermeyen bir veri seti, gerçek klinik koşullarda yetersiz performans gösterebilir. Bu nedenle geniş, heterojen ve çok merkezli veri setleri yapay zekâ modellerinin daha güvenilir hale gelmesi için gereklidir.

Eğitim süreçleri genellikle verinin eğitim, doğrulama ve test setlerine ayrılmasıyla yürütülür. Derin öğrenme modellerinde yüzlerce veya binlerce görüntü üzerinden tekrar eden iterasyonlar yapılır ve model parametreleri performans geri bildirimine göre optimize edilir. Aşırı uyumun engellenmesi için dropout, veri artırma ve erken durdurma gibi teknikler kullanılır. Bu süreçlerin uygun şekilde yürütülmesi, geliştirilen modelin hem doğruluk hem de klinik uygulanabilirlik açısından yeterli düzeye ulaşmasını sağlar.

5. ADNEKSİYEL KİTLELERDE YAPAY ZEKÂ UYGULAMALARI

5.1. Tanısal doğruluk ve malignite risk tahmini

Yapay zekâ algoritmalarının adneksiyel kitlelerdeki en önemli kullanım alanlarından biri, malignite riskinin daha doğru ve tutarlı şekilde tahmin edilmesidir. Geleneksel ultrason değerlendirmelerinde gözlemci deneyimi tanısal doğruluk üzerinde belirgin bir etkiye sahiptir ve bu durum özellikle sınırda bulguların bulunduğu olgularda değişken sonuçlara yol açabilir. Yapay zekâ temelli modeller, morfolojik özellikleri otomatik olarak tanımlayabilmesi ve çok boyutlu veriyi aynı anda analiz edebilmesi sayesinde bu değişkenliği azaltma potansiyeline sahiptir(S. Mitchell et al., 2024).

Derin öğrenme tabanlı görüntü analiz modelleri, ultrason görüntülerinde malignite ile ilişkili incelikli morfolojik özellikleri insan gözüne kıyasla daha ayrıntılı belirleyebilir. Bu modellerin, özellikle papiller çıkıntı, duvar düzensizliği ve solid komponent

gibi düz morfolojik bulguların yanında ekojenite dağılımı ve doku yapısını da ayırt etme becerisi, risk tahmin performansını artırmaktadır. Bazı çalışmalarda CNN tabanlı modellerin malignite sınıflamasında deneyimli klinisyenlere benzer hatta bazı alt gruplarda daha yüksek doğruluk oranlarına ulaştığı bildirilmiştir(Reilly et al., 2023).

Klinik verilere entegre edilen yapay zekâ modelleri ise yaş, menopoz durumu, tümör belirteçleri ve merkez tipi gibi parametrelerle birlikte görüntü verilerini kombine ederek daha kapsamlı risk skorları üretebilmektedir. Bu tür modellerin, malignite olasılığını kantitatif olarak belirleme ve düşük–yüksek risk ayırımını standartlaştırma konusunda mevcut yöntemlere kıyasla daha tutarlı sonuçlar verdiği gösterilmiştir(Kajal et al., 2026).

Yapay zekâ destekli risk tahmini, tek başına tanı koydurucu bir yöntem değildir; ancak klinisyenin değerlendirmesine güçlü bir ek bilgi sağlayarak hem gereksiz cerrahileri azaltma hem de malign olguları erken dönemde saptama açısından önemli katkı sunmaktadır.

5.2. Otomatik görüntü analizi

Otomatik görüntü analizi, yapay zekânın adneksiyel kitle değerlendirmesinde en güçlü olduğu alanlardan biridir. Bu yaklaşımda algoritmalar, ultrason görüntülerini doğrudan işler ve kitle morfolojisini tanımlamak için insan gözünden bağımsız bir değerlendirme gerçekleştirir. Model, görüntüdeki kenar, doku, ekojenite, septa, solid komponent ve papiller çıkıntı gibi yapıları otomatik olarak belirleyebilir. Bu da hem zaman kazandırır hem de gözlemciler arası değişkenliği azaltarak daha tutarlı sonuçlar ortaya koyar(Reilly et al., 2023).

Otomatik analiz yöntemlerinin bir diğer avantajı, görüntüde belirli bölgelerin manuel seçimine ihtiyaç duyulmamasıdır. Derin öğrenme tabanlı sistemler, görüntünün

tamamını tarayarak klinisyen tarafından fark edilmeyen veya daha zor seçilebilen ince ayrıntıları tespit edebilir. Bu özellik, özellikle heterojen yapıya sahip kompleks kitlelerde tanısal doğruluğu artırabilir. Ayrıca otomatik segmentasyon yöntemleri, kitle hacmini, sınırlarını ve iç yapısını yüksek doğrulukla ölçerek takip süreçlerinde objektif veri sağlar.

Literatürde, otomatik görüntü analizi modellerinin benign–malign ayrımında tek başına ultrason değerlendirmesine kıyasla daha yüksek duyarlılık ve özgüllük oranlarına ulaşabildiği çalışmalar bulunmaktadır(Kapoor et al., 2024). Bununla birlikte bu modellerin gerçek klinik uygulamaya entegrasyonu için cihazlar arası uyumu, görüntü kalitesindeki değişkenlikleri ve farklı merkezlerdeki popülasyon farklılıklarını dikkate alan daha geniş çalışmalara ihtiyaç duyulmaktadır.

5.3. Kitle morfolojisinin yapay zekâ ile sınıflandırılması

Adneksiyel kitlelerin morfolojik özellikleri, malignite riskinin belirlenmesinde en kritik unsurlardan biridir. Geleneksel ultrason değerlendirmesinde sınıflandırma, duvar yapısı, septasyon, papiller çıkıntı, solid komponent varlığı ve ekojenite dağılımı gibi bulguların klinisyen tarafından yorumlanmasına dayanır. Ancak bu süreç, doğal olarak deneyime bağlı farklılıklar gösterebilir ve özellikle belirsiz morfolojili lezyonlarda tutarsız sonuçlara yol açabilir. Yapay zekâ bu noktada, morfolojik özellikleri otomatik ve objektif şekilde analiz ederek önemli bir avantaj sunmaktadır(Christiansen et al., 2025).

Derin öğrenme mimarileri özellikle konvolüsyonel sinir ağları, morfolojik sınıflandırma sürecinde görüntüdeki ince yapısal detayları katman katman analiz ederek çok boyutlu bir özellik çıkarımı gerçekleştirir. Bu süreçte model, yalnızca belirgin morfolojik unsurları değil; insan gözünün fark etmekte zorlanabileceği mikro yapıları, doku örüntülerini ve ekojenite

farklılıklarını da tanır. Böylece benign, borderline ve malign süreçleri ayırt etmede daha yüksek doğruluk elde edilebilir.

Bazı çalışmalarda derin öğrenme tabanlı sınıflandırma modellerinin, kompleks kitlelerde deneyimli klinisyenlerle benzer hatta bazı alt gruplarda daha iyi performans gösterdiği bildirilmiştir. Bu modeller, morfolojik risk skorları ile kombine edildiğinde hem subjektif değerlendirmeyi azaltmakta hem de hastaların uygun yönetim seçeneklerine daha doğru yönlendirilmesini sağlamaktadır(Grigore et al., 2020).

Yine de yapay zekâ temelli sınıflandırma sistemlerinin güçlü bir klinik araç haline gelmesi için farklı cihazlar, görüntü kaliteleri ve hasta popülasyonları üzerinde doğrulanması gerekmektedir.

5.4. Mevcut modeller ve performans karşılaştırmaları

Adneksiyel kitlelerin değerlendirilmesinde yapay zekâ modelleri son yıllarda giderek çeşitlenmiş ve performans karşılaştırmaları literatürde önemli bir yer edinmiştir. Bu modeller arasında en sık kullanılanlar; derin öğrenme tabanlı konvolüsyonel sinir ağları, hibrit (klinik + görüntü) modeller ve geleneksel makine öğrenmesi algoritmalarıdır. Model performansı genellikle doğruluk, duyarlılık, özgüllük, F1 skoru ve ROC eğrisi altındaki alan (AUC) gibi metriklerle değerlendirilir(Van Holsbeke et al., 2012).

CNN tabanlı modeller, özellikle ultrason görüntülerinde morfolojik özelliklerin tanınması ve malignite risk sınıflamasında dikkat çekici sonuçlar ortaya koymuştur. Bazı modeller benign–malign ayırımında yüzde 90’a yaklaşan doğruluk oranlarına ulaşırken, kompleks morfolojiye sahip kitlelerde deneyimli klinisyenlerle aynı seviyede performans gösterebildikleri bildirilmiştir. Hibrit modeller ise hem görüntü verisini hem de yaş, menopoz durumu, CA-125 düzeyi gibi klinik parametreleri

bir arada değerlendirerek daha kapsamlı risk tahmini sağlayabilmektedir.

Performans karşılaştırmalarında dikkati çeken bir diğer nokta, tek merkezli veri setiyle eğitilen modellerin başka merkezlerde aynı başarıyı gösterememesidir. Görüntü kalitesi, cihaz farkları ve hasta popülasyonundaki değişkenlik, modellerin genellenabilirliğini doğrudan etkileyebilir. Bu nedenle geniş, çok merkezli ve heterojen veri setleri ile eğitilen modellerin klinik uygulamaya daha uygun olduğu görülmektedir(Suleman et al., 2025).

Sonuç olarak mevcut yapay zekâ modelleri umut verici performans sergilese de, klinik geçerliliğin artırılması için standardizasyon, dış doğrulama ve gerçek hasta akışında test edilme aşamaları kritik öneme sahiptir.

6. CERRAHİ KARAR VERME SÜRECİNDE YAPAY ZEKÂ

6.1. Operasyon endikasyonu belirleme

Adneksiyel kitlelerde operasyon endikasyonunun doğru belirlenmesi, hem gereksiz cerrahilerin önlenmesi hem de malign olguların zamanında tespit edilmesi açısından kritik bir aşamadır. Geleneksel yaklaşımda cerrahi karar; ultrason bulguları, tümör belirteçleri, hastanın yaşı, menopoz durumu ve klinik semptomların birlikte değerlendirilmesine dayanır. Ancak bu süreçte özellikle borderline veya belirsiz morfolojiye sahip olgularda karar vermek güçleşebilir ve uygulayıcı deneyimine bağlı farklılıklar ortaya çıkabilir(American College of Obstetricians and Gynecologists' Committee on Practice Bulletins—Gynecology, 2016).

Yapay zekâ uygulamaları, operasyon gerekliliğini tahmin etmeye yönelik modeller geliştirilmesine olanak sağlamıştır. Bu

modeller; kitle morfolojisi, solid komponent varlığı, vaskülarite özellikleri, klinik parametreler ve laboratuvar bulgularını aynı anda analiz ederek potansiyel risk düzeyini hesaplayabilir. Böylece düşük riskli olgularda konservatif yaklaşımın güvenle sürdürülebilmesi, yüksek riskli olgularda ise cerrahi planlamanın daha net yapılabilmesi mümkün olur.

Ayrıca yapay zekâ temelli sistemler, klinisyenler arasında karar birliğini artırarak operasyon endikasyonu belirleme sürecini daha standart ve öngörülebilir hale getirebilir. Gelecekte bu modellerin, multidisipliner tümör konseyleri ve referans merkezlere yönlendirme kararlarında tamamlayıcı bir araç olarak daha yaygın kullanılacağı öngörülmektedir.

6.2. Minimal invaziv cerrahide karar destek sistemleri

Minimal invaziv cerrahi, adneksiyel kitlelerin yönetiminde hem tanısal hem de tedavi edici amaçlarla yaygın olarak kullanılan bir yaklaşımdır. Laparoskopi sırasında anatomik yapıların net şekilde görülmesi ve kritik bölgelerin güvenli şekilde diseke edilmesi, cerrahi başarının temel unsurlarındandır. Yapay zekâ temelli karar destek sistemleri, bu süreçte cerraha ek bir güvenlik katmanı sunarak operasyon sırasında görüntü optimizasyonu, doku tanıma ve kritik yapıların işaretlenmesi gibi fonksiyonlar sağlayabilmektedir(Ikeda et al., 2025).

Derin öğrenme tabanlı modeller, laparoskopik görüntülerde uterus, over, tuba ve çevre dokuların otomatik olarak tanımlanmasına yardımcı olabilir. Bu sayede özellikle zor anatomik bölgelerde diseksiyon planlamasının daha öngörülebilir hale gelmesi mümkün olur. Ayrıca kanama riskinin yüksek olduğu alanların erken belirlenmesi veya şüpheli doku bölgelerinin işaretlenmesi operasyon güvenliğini artırabilir.

Bu tür karar destek sistemleri henüz klinik rutine tam olarak entegre olmasa da, gelecekte minimal invaziv cerrahinin

daha standart, hızlı ve güvenli bir şekilde uygulanmasına katkı sağlayacağı öngörülmektedir.

6.3. İntraoperatif görüntü destekli yapay zekâ uygulamaları

İntraoperatif görüntü destekli yapay zekâ uygulamaları, cerrahi sırasında gerçek zamanlı veri analizi yaparak cerrahın karar sürecine anlık katkı sağlamayı amaçlamaktadır. Özellikle laparoskopik girişimlerde elde edilen görüntüler, derin öğrenme algoritmaları tarafından eş zamanlı olarak analiz edilerek doku sınırlarının belirlenmesi, şüpheli alanların işaretlenmesi ve anatomik yapıların otomatik tanınması mümkün hale gelmektedir(Reilly et al., 2023).

Bu tür sistemler, malignite şüphesi bulunan adneksiyel kitlelerde tümör sınırlarının daha net ortaya konmasına ve rezeksiyon planının daha güvenli yapılmasına yardımcı olabilir. Ayrıca intraoperatif görüntü işleme sayesinde cerrahi alanın büyütülmesi, kontrast artırımı ve doku farklılıklarının belirginleştirilmesi sağlanarak komplikasyon riski azaltılabilir.

Her ne kadar bu teknolojiler henüz yaygın klinik kullanım aşamasında olmasa da, gelecekte yapay zekâ destekli cerrahi platformların standart operasyon pratiğinin bir parçası haline gelmesi beklenmektedir.

7. KLİNİK KULLANIMA YÖNELİK SINIRLILIKLAR VE ZORLUKLAR

7.1. Veri güvenliği ve etik konular

Yapay zekâ temelli sistemlerin klinik uygulamalara entegrasyonunda veri güvenliği ve etik ilkeler büyük önem taşır. Tıbbi görüntüler, klinik bilgiler ve laboratuvar sonuçları yüksek derecede hassas kişisel veriler olduğundan, bu verilerin anonimleştirilmesi ve güvenli şekilde saklanması yasal bir

zorunluluktur. Özellikle çok merkezli veri setlerinin oluşturulması sürecinde, veri paylaşımı sırasında hasta mahremiyetinin korunması temel bir prensip olarak ele alınmalıdır(Schulze et al., 2023).

Etik açıdan en önemli sorunlardan biri, yapay zekâ modellerinin kararlarının şeffaf olmamasıdır. Derin öğrenme algoritmalarının “kara kutu” yapısı, modelin hangi özelliklere dayanarak risk tahmini yaptığını her zaman açıkça göstermeyebilir. Bu durum, klinik karar süreçlerinde sorumluluğun kimde olduğu ve model çıktılarının ne ölçüde güvenilir kabul edileceği gibi tartışmaları gündeme getirmektedir.

Ayrıca algoritmaların eğitildiği veri setlerinin belirli popülasyonlara ait olması, farklı demografik gruplarda performans düşüklüğüne neden olabilir. Bu nedenle etik kullanım, modelin adil, şeffaf ve klinik açıdan güvenilir olmasını gerektirir.

7.2. Model genellenebilirliği

Yapay zekâ modellerinin klinik uygulamadaki başarısı, yalnızca eğitim verisi üzerindeki performanslarına değil, farklı merkezlerde ve farklı hasta popülasyonlarında benzer sonuçlar verebilme yeteneklerine bağlıdır. Bu özellik “genellenebilirlik” olarak tanımlanır ve tıbbi görüntüleme alanında özellikle önemlidir. Eğitim verisi belirli bir cihaz, merkez veya popülasyonla sınırlıysa, model başka ortamlarda beklenen doğruluğa ulaşamayabilir(Zhou et al., 2025).

Cihazlar arası görüntü kalitesi farklılıkları, operatör deneyimi, demografik değişkenlikler ve klinik pratiğe özgü yaklaşımlar model performansını doğrudan etkileyebilir. Bu nedenle geniş, heterojen ve çok merkezli veri setleriyle eğitilmiş modeller, gerçek klinik kullanımda daha güvenilir sonuçlar verme potansiyeline sahiptir.

7.3. Klinik entegrasyon sorunları

Yapay zekâ modellerinin klinik pratiğe entegrasyonu, teknik yeterlilik kadar uygulama koşullarının da uygun olmasını gerektirir. En önemli sorunlardan biri, yapay zekâ sistemlerinin mevcut hastane altyapılarıyla sorunsuz çalışmasını sağlayacak teknolojik uyumluluğun her kurumda aynı düzeyde olmamasıdır. Görüntü aktarımı, veri işleme kapasitesi ve entegrasyon yazılımlarının eksikliği model performansını sınırlayabilir(Bujotzek et al., 2025).

Bir diğer önemli engel, klinisyenlerin yapay zekâ çıktılarının nasıl yorumlanacağı konusunda yeterli eğitim ve güvene sahip olmamasıdır. Model önerilerinin hangi parametrelere dayandığını açıklamayan sistemler, karar sürecinde tereddüt yaratabilir. Ayrıca yapay zekâ sonuçlarının klinik akışa entegre edilmesi için zaman yönetimi, iş yükü ve operasyonel süreçlerde ek düzenlemeler gerekebilir.

Tüm bu nedenlerle yapay zekânın klinik pratiğe başarılı bir şekilde yerleşebilmesi, teknolojik altyapı uyumu, kullanıcı eğitimi ve sistemlerin şeffaflığı gibi birden fazla bileşimin birlikte ele alınmasını gerektirir.

8. GELECEK PERSPEKTİFİ

Adneksiyel kitlelerin değerlendirilmesinde yapay zekâ uygulamalarının geleceği hem teknolojik gelişmelere hem de klinik kullanımın yaygınlaşmasına paralel olarak giderek daha umut verici bir hâl almaktadır. Özellikle daha büyük, heterojen ve çok merkezli veri setlerinin oluşturulması, modellerin genellenebilirliğini artırarak gerçek klinik koşullarda daha tutarlı performans göstermelerini sağlayacaktır. Bu veri setlerinin geliştirilmesi, farklı cihaz ve görüntüleme protokollerinden

kaynaklanan varyasyonların minimize edilmesi açısından kritik öneme sahiptir(Abdalla Mohammed et al., 2025).

Gelecekte yapay zekâ algoritmalarının yalnızca görüntü analizi yapmakla kalmayıp, laboratuvar bulguları, genetik veriler, biyobelirteçler ve klinik değişkenlerle entegre çalışan çok boyutlu karar destek sistemlerine dönüşmesi beklenmektedir. Böylece malignite riskinin daha doğru tahmini, cerrahi planlamanın daha net yapılması ve hasta yönetim stratejilerinin daha kişiselleştirilmesi mümkün olabilir.

Aynı zamanda yapay zekânın intraoperatif süreçlere daha fazla entegre edilmesi, cerrahi güvenliği artıracak yeni uygulamaların ortaya çıkmasına katkı sağlayacaktır. Gerçek zamanlı görüntü işleme, doku sınıflandırma ve anatomik yapı tanıma gibi fonksiyonların operasyon sırasında standart hale gelmesi, hem komplikasyon oranlarının azalmasına hem de cerrahi sürecin daha kontrollü ilerlemesine olanak tanıyabilir.

Tüm bu gelişmeler ışığında, yapay zekânın önümüzdeki yıllarda adneksiyel kitle yönetiminde tamamlayıcı bir araçtan çok daha kapsamlı, bütüncül bir klinik destek sistemi hâline gelmesi beklenmektedir.

9. SONUÇ

Adneksiyel kitlelerin değerlendirilmesi, kadın hastalıkları ve doğum pratiğinde hem tanısal hem de yönetsel açıdan en fazla zorluk içeren klinik alanlardan biridir. Geleneksel yaklaşım; klinik bilgi, ultrason bulguları ve laboratuvar sonuçlarının bir arada yorumlanmasına dayanmakla birlikte, bu süreçte gözlemci bağımlılığı ve belirsiz olguların yönetimindeki güçlükler hâlâ önemli bir sorun oluşturmaktadır. Yapay zekâ uygulamaları, bu noktada farklı veri kaynaklarını bütüncül bir şekilde analiz ederek tanısal doğruluğu artırma ve karar verme süreçlerini

standartlaştırma potansiyeliyle giderek daha dikkat çekici hâle gelmiştir.

Derin öğrenme tabanlı görüntü analiz modelleri, adneksiyel kitle morfolojisinin daha ayrıntılı ve objektif şekilde değerlendirilmesine olanak tanırken, klinik verilerin entegre edildiği hibrit modeller risk tahminini daha tutarlı hale getirebilmektedir. Cerrahi süreçlerde gerçek zamanlı görüntü işleme ve karar destek sistemleri ise operasyon güvenliğini artırma olanağı sunmaktadır.

Tüm bu veriler ışığında, yapay zekânın adneksiyel kitle yönetiminde klinisyenin yerini alması beklenmemekle birlikte, doğru kullanıldığında güçlü bir tamamlayıcı araç olacağı açıktır. Gelecek yıllarda daha geniş veri setleri, standartlaşmış modeller ve gelişmiş entegrasyon sistemleriyle yapay zekânın klinik pratikte daha merkezi bir rol üstlenmesi öngörülmektedir.

KAYNAKLAR

- Abdalla Mohammed, F. S., Ahmed Eisa, S. M., Abdalla Madani, A. M., Alrowili, N. M. F., Al Ghaythan, A. M. K., Mohamed Ali, I. M., Elamin, L., & Abdirahman Salad, N. (2025). Artificial Intelligence in Ultrasound-Based Diagnoses of Gynecological Tumors: A Systematic Review. *Cureus*, 17(6), e85884. <https://doi.org/10.7759/cureus.85884>
- Almeida, G., Bort, M., & Alcázar, J. L. (2025). Comparison of the Diagnostic Performance of Ovarian Adnexal Reporting Data System (O-RADS) With IOTA Simple Rules and ADNEX Model for Classifying Adnexal Masses: A Head-To-Head Meta-Analysis. *Journal of Clinical Ultrasound*, 53(7), 1574–1583. <https://doi.org/10.1002/jcu.24048>
- American College of Obstetricians and Gynecologists' Committee on Practice Bulletins—Gynecology. (2016). Practice Bulletin No. 174: Evaluation and Management of Adnexal Masses. *Obstetrics and Gynecology*, 128(5), e210–e226. <https://doi.org/10.1097/AOG.0000000000001768>
- Andreotti, R. F., Timmerman, D., Strachowski, L. M., Froyman, W., Benacerraf, B. R., Bennett, G. L., Bourne, T., Brown, D. L., Coleman, B. G., Frates, M. C., Goldstein, S. R., Hamper, U. M., Horrow, M. M., Hernanz-Schulman, M., Reinhold, C., Rose, S. L., Whitcomb, B. P., Wolfman, W. L., & Glanc, P. (2020). O-RADS US Risk Stratification and Management System: A Consensus Guideline from the ACR Ovarian-Adnexal Reporting and Data System Committee. *Radiology*, 294(1), 168–185. <https://doi.org/10.1148/radiol.2019191150>

- Ardakani, A. A., Mohammadi, A., Mohebbi, A., Vijayananthan, A., Leong, S. S., Ting, L. Y., Fabell, M. K. B. M., Acharya, U. R., & Hatamikia, S. (2025). *From ACR O-RADS 2022 to Explainable Deep Learning: Comparative Performance of Expert Radiologists, Convolutional Neural Networks, Vision Transformers, and Fusion Models in Ovarian Masses*.
- Bujotzek, M. R., Aküna, Ü., Denner, S., Neher, P., Zenk, M., Frodl, E., Jaiswal, A., Kim, M., Krekic, N. R., Nickel, M., Ruppel, R., Both, M., Döllinger, F., Opitz, M., Persigehl, T., Kleesiek, J., Penzkofer, T., Maier-Hein, K., Bucher, A., & Braren, R. (2025). Real-world federated learning in radiology: hurdles to overcome and benefits to gain. *Journal of the American Medical Informatics Association : JAMIA*, 32(1), 193–205. <https://doi.org/10.1093/jamia/ocae259>
- Chankrachang, A., Lattiwongsakorn, W., Tantipalakorn, C., & Tongsong, T. (2025). Diagnostic Performance of ADNEX Model and IOTA Simple Rules in Differentiating Malignant from Benign Adnexal Masses When Assessed by Non-Expert Examiners. *Journal of Clinical Medicine*, 14(8). <https://doi.org/10.3390/jcm14082776>
- Christiansen, F., Konuk, E., Ganeshan, A. R., Welch, R., Palés Huix, J., Czekierdowski, A., Leone, F. P. G., Haak, L. A., Fruscio, R., Gaurilcikas, A., Franchi, D., Fischerova, D., Mor, E., Savelli, L., Pascual, M. À., Kudla, M. J., Guerriero, S., Buonomo, F., Liuba, K., ... Epstein, E. (2025). International multicenter validation of AI-driven ultrasound detection of ovarian cancer. *Nature Medicine*, 31(1), 189–196. <https://doi.org/10.1038/s41591-024-03329-4>

- Davenport, C., Rai, N., Sharma, P., Deeks, J. J., Berhane, S., Mallett, S., Saha, P., Champaneria, R., Bayliss, S. E., Snell, K. I., & Sundar, S. (2022). Menopausal status, ultrasound and biomarker tests in combination for the diagnosis of ovarian cancer in symptomatic women. *The Cochrane Database of Systematic Reviews*, 7(7), CD011964.
<https://doi.org/10.1002/14651858.CD011964.pub2>
- Erdodi, B., Szollosi, G. J., Toth, Z., Krasznai, Z. T., & Jakab, A. (2025). The Clinical Relevance of Distinguishing Between Simple and Complex Adnexal Cystic Structures by Ultrasound in Peri- and Postmenopause. *Cancers*, 17(8). <https://doi.org/10.3390/cancers17081370>
- Grigore, M., Popovici, R. M., Gafitanu, D., Himiniuc, L., Murarasu, M., & Micu, R. (2020). Logistic models and artificial intelligence in the sonographic assessment of adnexal masses - a systematic review of the literature. *Medical Ultrasonography*, 22(4), 469–475.
<https://doi.org/10.11152/mu-2538>
- Hiett, A. K., Sonek, J. D., Guy, M., & Reid, T. J. (2022). Performance of IOTA Simple Rules, Simple Rules risk assessment, ADNEX model and O-RADS in differentiating between benign and malignant adnexal lesions in North American women. *Ultrasound in Obstetrics & Gynecology: The Official Journal of the International Society of Ultrasound in Obstetrics and Gynecology*, 59(5), 668–676.
<https://doi.org/10.1002/uog.24777>
- Ikeda, J., Takeuchi, M., Kawakubo, H., Yura, M., Kinoshita, T., Morito, A., Nunobe, S., Morimoto, Y., Egawa, T., Furube, T., Maeda, Y., Matsuda, S., & Kitagawa, Y. (2025). Assessment of AI-driven anatomical recognition in

- robotic gastrectomy: A multicenter retrospective analysis. *Surgical Endoscopy*, 39(12), 8349–8356. <https://doi.org/10.1007/s00464-025-12248-5>
- Jeong, Y. Y., Outwater, E. K., & Kang, H. K. (2000). Imaging evaluation of ovarian masses. *Radiographics : A Review Publication of the Radiological Society of North America, Inc*, 20(5), 1445–1470. <https://doi.org/10.1148/radiographics.20.5.g00se101445>
- Jiang, Z., Pu, W., Luo, X., Zhang, J., Jia, S., Zhang, G., & Zhu, Y. (2025). Integrating O-RADS US v2022, CEUS, and CA125 to enhance the diagnostic differentiation of ovarian masses: development of the OCC-US model. *Cancer Imaging: The Official Publication of the International Cancer Imaging Society*, 25(1), 96. <https://doi.org/10.1186/s40644-025-00918-5>
- Kaijser, J. (2015). Towards an evidence-based approach for diagnosis and management of adnexal masses: findings of the International Ovarian Tumour Analysis (IOTA) studies. *Facts, Views & Vision in ObGyn*, 7(1), 42–59.
- Kaijser, J., Bourne, T., Valentin, L., Sayasneh, A., Van Holsbeke, C., Vergote, I., Testa, A. C., Franchi, D., Van Calster, B., & Timmerman, D. (2013). Improving strategies for diagnosing ovarian cancer: a summary of the International Ovarian Tumor Analysis (IOTA) studies. *Ultrasound in Obstetrics & Gynecology: The Official Journal of the International Society of Ultrasound in Obstetrics and Gynecology*, 41(1), 9–20. <https://doi.org/10.1002/uog.12323>
- Kajal, D., Nanapragasam, A., Leckie, A., Sagheb, S., Nasri, F., Bouchard-Fortier, G., Solnik, J., & Atri, M. (2026). Ultrasound Ovarian-Adnexal Reporting and Data System (O-RADS) and modified ultrasound simple rules

- comparison in evaluation of surgically proven adnexal masses. *Clinical Radiology*, 92, 107180. <https://doi.org/10.1016/j.crad.2025.107180>
- Kapoor, S., Singhal, S., Dhamija, E., Manchanda, S., Malhotra, N., & Bhatla, N. (2024). Diagnostic performance of ultrasound reporting systems in evaluation of adnexal masses: A prospective observational study. *European Journal of Obstetrics, Gynecology, and Reproductive Biology*, 301, 186–193. <https://doi.org/10.1016/j.ejogrb.2024.08.023>
- Liu, L., Cai, W., Tian, H., Wu, B., Zhang, J., Wang, T., Hao, Y., & Yue, G. (2024). Ultrasound image-based nomogram combining clinical, radiomics, and deep transfer learning features for automatic classification of ovarian masses according to O-RADS. *Frontiers in Oncology*, 14, 1377489. <https://doi.org/10.3389/fonc.2024.1377489>
- Liu, X., Faes, L., Kale, A. U., Wagner, S. K., Fu, D. J., Bruynseels, A., Mahendiran, T., Moraes, G., Shamdas, M., Kern, C., Ledsam, J. R., Schmid, M. K., Balaskas, K., Topol, E. J., Bachmann, L. M., Keane, P. A., & Denniston, A. K. (2019). A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *The Lancet. Digital Health*, 1(6), e271–e297. [https://doi.org/10.1016/S2589-7500\(19\)30123-2](https://doi.org/10.1016/S2589-7500(19)30123-2)
- Mitchell, D. G., Javitt, M. C., Glanc, P., Bennett, G. L., Brown, D. L., Dubinsky, T., Harisinghani, M. G., Harris, R. D., Horowitz, N. S., Pandharipande, P. V., Pannu, H. K., Podrasky, A. E., Royal, H. D., Shipp, T. D., Siegel, C. L., Simpson, L., Wong-You-Cheong, J. J., Zelop, C. M., & American College of Radiology. (2013). ACR appropriateness criteria staging and follow-up of ovarian

- cancer. *Journal of the American College of Radiology : JACR*, 10(11), 822–827.
<https://doi.org/10.1016/j.jacr.2013.07.017>
- Mitchell, S., Nikolopoulos, M., El-Zarka, A., Al-Karawi, D., Al-Zaidi, S., Ghai, A., Gaughran, J. E., & Sayasneh, A. (2024). Artificial Intelligence in Ultrasound Diagnoses of Ovarian Cancer: A Systematic Review and Meta-Analysis. *Cancers*, 16(2).
<https://doi.org/10.3390/cancers16020422>
- Moro, F., Momi, M., Ledger, A., Barreñada, L., Ceusters, J., Sturla, D., Mor, E., Fornari, L., Mascilini, F., Ciccarone, F., Pozzati, F., Froyman, W., Van Calster, B., Bourne, T., Timmerman, D., Fagotti, A., Valentin, L., Testa, A. C., & IOTA 6 Collaborators. (2025). External validation of ultrasound-based models for differentiating between benign and malignant adnexal masses: a nationwide prospective multicenter study (IOTA phase 6). *American Journal of Obstetrics and Gynecology*, 233(6), 629.e1-629.e13. <https://doi.org/10.1016/j.ajog.2025.07.017>
- Moro, F., Vagni, M., Tran, H. E., Bernardini, F., Mascilini, F., Ciccarone, F., Nero, C., Giannarelli, D., Boldrini, L., Fagotti, A., Scambia, G., Valentin, L., & Testa, A. C. (2025). Radiomics analysis of ultrasound images to discriminate between benign and malignant adnexal masses with solid morphology on ultrasound. *Ultrasound in Obstetrics & Gynecology*, 65(3), 353–363. <https://doi.org/10.1002/uog.27680>
- Padival, A., Patel, B. M., Parekh, C. D., Arora, R., & Naik, K. (2025). Preoperative Risk Stratification of Adnexal Masses: A Narrative Review of Diagnostic Models and the International Ovarian Tumor Analysis (IOTA) Assessment of Different Neoplasias in the Adnexa

- (ADNEX) Performance. *Cureus*.
<https://doi.org/10.7759/cureus.97027>
- Reilly, G. P., Dunton, C. J., Bullock, R. G., Ure, D. R., Fritsche, H., Ghosh, S., Pappas, T. C., & Phan, R. T. (2023). Validation of a deep neural network-based algorithm supporting clinical management of adnexal mass. *Frontiers in Medicine*, 10, 1102437. <https://doi.org/10.3389/fmed.2023.1102437>
- Sayasneh, A., Wynants, L., Preisler, J., Kaijser, J., Johnson, S., Stalder, C., Husicka, R., Abdallah, Y., Raslan, F., Drought, A., Smith, A. A., Ghaem-Maghami, S., Epstein, E., Van Calster, B., Timmerman, D., & Bourne, T. (2013). Multicentre external validation of IOTA prediction models and RMI by operators with varied training. *British Journal of Cancer*, 108(12), 2448–2454. <https://doi.org/10.1038/bjc.2013.224>
- Schulze, A., Tran, D., Daum, M. T. J., Kisilenko, A., Maier-Hein, L., Speidel, S., Distler, M., Weitz, J., Müller-Stich, B. P., Bodenstedt, S., & Wagner, M. (2023). Ensuring privacy protection in the era of big laparoscopic video data: development and validation of an inside outside discrimination algorithm (IODA). *Surgical Endoscopy*, 37(8), 6153–6162. <https://doi.org/10.1007/s00464-023-10078-x>
- Singh, S. P., Ramprasad, A., & Makary, M. S. (2025). Clinical utility of artificial intelligence models in radiology: a systemic scoping review of diagnostic and endovascular applications. *CVIR Endovascular*, 8(1), 97. <https://doi.org/10.1186/s42155-025-00573-8>
- Suleman, M. U., Mursaleen, M., Khalil, U., Saboor, A., Bilal, M., Khan, S. A., Subhani, M. A., Hussnain, M. A., Tabassum, S. N., & Tahir, M. (2025). Assessing the generalizability

of artificial intelligence in radiology: a systematic review of performance across different clinical settings. *Annals of Medicine and Surgery* (2012), 87(12), 8803–8811. <https://doi.org/10.1097/MS9.00000000000004166>

Timmerman, D., Ameye, L., Fischerova, D., Epstein, E., Melis, G. B., Guerriero, S., Van Holsbeke, C., Savelli, L., Fruscio, R., Lissoni, A. A., Testa, A. C., Veldman, J., Vergote, I., Van Huffel, S., Bourne, T., & Valentin, L. (2010). Simple ultrasound rules to distinguish between benign and malignant adnexal masses before surgery: prospective validation by IOTA group. *BMJ*, 341(dec14 1), c6839–c6839. <https://doi.org/10.1136/bmj.c6839>

Van Holsbeke, C., Van Calster, B., Bourne, T., Ajossa, S., Testa, A. C., Guerriero, S., Fruscio, R., Lissoni, A. A., Czekierdowski, A., Savelli, L., Van Huffel, S., Valentin, L., & Timmerman, D. (2012). External validation of diagnostic models to estimate the risk of malignancy in adnexal masses. *Clinical Cancer Research : An Official Journal of the American Association for Cancer Research*, 18(3), 815–825. <https://doi.org/10.1158/1078-0432.CCR-11-0879>

Vázquez-Manjarrez, S. E., Rico-Rodriguez, O. C., Guzman-Martinez, N., Espinoza-Cruz, V., & Lara-Nuñez, D. (2020). Imaging and diagnostic approach of the adnexal mass: what the oncologist should know. *Chinese Clinical Oncology*, 9(5), 69–69. <https://doi.org/10.21037/cco-20-37>

Venturini, L., Budd, S., Farruggia, A., Wright, R., Matthew, J., Day, T. G., Kainz, B., Razavi, R., & Hajnal, J. V. (2025). Whole examination AI estimation of fetal biometrics from 20-week ultrasound scans. *NPJ Digital Medicine*, 8(1), 22. <https://doi.org/10.1038/s41746-024-01406-z>

- Wheeler, V., Umstead, B., & Chadwick, C. (2023). Adnexal Masses: Diagnosis and Management. *American Family Physician*, 108(6), 580–587.
- Yoeli-Bik, R., Whitney, H. M., Li, H., Bilecz, A., Abramowicz, J. S., Lan, L., Longman, R. E., Giger, M. L., & Lengyel, E. (2025). Hybrid artificial intelligence echogenic components-based diagnosis of adnexal masses on ultrasound. *Medical Physics*, 52(7). <https://doi.org/10.1002/mp.17983>
- Zhang, Y., & Nie, H. (2022). Design and Implementation of Obstetric Central Monitoring System Based on Medical Image Segmentation Algorithm. *Journal of Healthcare Engineering*, 2022, 3545831. <https://doi.org/10.1155/2022/3545831>
- Zhou, Z., Luo, G., Chen, M., Weng, Z., & Zhu, Y. (2025). Federated Learning for Medical Image Classification: A Comprehensive Benchmark. *IEEE Journal of Biomedical and Health Informatics*, PP. <https://doi.org/10.1109/JBHI.2025.3631706>

İN VİTRO FERTİLİZASYON TEDAVİSİNDE YAPAY ZEKA UYGULAMALARI VE GELECEĞİ

Yasemin ERCAN DEĞİRMENCİ¹

Rulin DENİZ²

1. GİRİŞ

Dünya çapında her altı çiftten biri infertildir (Graham M.E. et al,2023). İVF tedavisi infertil çiftlerde kurtarıcı bir tedavi yöntemi olmuştur. Son yıllarda teknolojinin gelişmesiyle birlikte, İVF tedavisinde büyük değişiklikler olmasına rağmen gebelik elde etme oranları %30 ve canlı doğum elde etme oranları daha da düşüktür. 42 yaş ve üzerinde kadınlarda gebelik elde etme oranları %4 altında olabilmektedir (Smith et al,2015). Embiryo seçimi ve morfolojisinin şimdiye kadar olan geleneksel yaklaşımlar kişi ve deneyim bağımlı olmuştur, bu da beraberinde başarı oranlarında değişkenliği getirmiştir. Yapay zekanın makine öğrenimi (ML), derin öğrenme (DL) modellerinin İVF tedavi aşamalarına entegrasyonu ile başarı oranlarını yükseltmeye ve bu dezavantajları ortadan kaldırmaya olanak sağlama amacı güdülmüştür. Ovulasyon indüksiyon protokollerinin kişiye özgü düzenlenmesi, sperm, gamet ve embiryo seçiminde zaman atlamalı görüntü modellerinin yapay zekaya entegrasyonu gibi uygulamalar ile başarı oranları artabilmektedir. Çok büyük ve kapsamlı verilerin elle işlenmesi ve analizinin yapılması oldukça zordur. Yapay zekanın büyük ölçekli verileri analiz edebilme

¹ Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Kadın Hastalıkları ve Doğum Anabilim, ORCID: 0009-0001-5591-7997.

² Doç. Dr, Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Kadın Hastalıkları ve Doğum Anabilim, ORCID: 0000-0002-7306-8212.

özelliği nedeniyle kişiye özgü ovulasyon indüksiyon protokolleri oluşturma, ek tedavi algoritmaları oluşturabilme imkanı yaratır. Yapay zeka uygulamalarının algoritma ve model programlaması güvenlik açığı bulunmadan oluşturulmaya çalışılmaktadır. Ancak yapay zeka uygulaması programlanırken gözden kaçan güvenlik açıklarının kötü yönde kullanılabilme olasılığı önemli bir problemdir. Aynı zamanda yapay zekanın destekleyici etkisinin yanında başarısız olduğu takdirde sorumluluğun kimde olduğu en önemli etik problemdir. Bu yüzden yapay zekayı destekleyici güç olarak düşünmek gerekir. Aynı zamanda tedavi süreçlerine sağlayabileceği büyük katkılar içinde tedavi sürecindeki yeri arttırılmalıdır.

2. YAPAY ZEKA VE MAKİNE ÖĞRENİMİ: TEMEL KAVRAMLAR

2.1. Yapay zeka(AI)


Yapay zeka ile bilgisayarların insan benzeri düşünme, karar verme, öğrenme ve problem çözme yeteneklerinin taklit edilmesi sağlanmaya çalışılmaktadır (Sheikh et al,2023). Bir grup bilgisayar mühendisi, 1956 yılında bilgisayarın düşünmek ve öğrenmek için programlanabileceği düşüncesi ile yapay zeka çalışmalarına başlamıştır. Bu prensibi ‘yapay zeka’ olarak tanımladılar (Moor J,2006). Yapay zeka, temel olarak veri bilimi alanına girer ve makine öğrenimini ve klasik programlamayı içerir. Makine öğrenimi (ML), derin öğrenme (DL) ve yapay sinir ağları dahil olmak üzere birçok model içerir. Yapay zeka farklı disiplinlerde, teorik çerçevesi ve uygulamalarına göre değişiklik göstermektedir. Yapay zeka, yapay genel zeka (AGI) ve yapay dar zeka (ANI) olarak ikiye ayrılmaktadır. Yapay genel zeka, herhangi bir ortamda öğrenen ve hareket eden evrensel bir algoritmadır. Yaklaşık olarak insan düzeyinde bir zekadır. Ortalama bir insanın farklı ortam ve durumlardaki bilişsel

görevlerini yerine getirebilen yapay genel zeka, yapay zekadaki mevcut gelişim düzeyinde şu an için imkansızdır. Yapay dar zeka ise genellikle herhangi bir alanda uzman olan insandan beklendiği gibi tanımlanmış sınırlar içinde görevleri yerine getiren algoritmalarlardır. Yapay zeka, temelde insanlar tarafından gerçekleştirilen entelektüel görevleri otomatikleştirmeye odaklanan bir alandır ve makine öğrenimi, derin öğrenme bu hedefe ulaşmanın yöntemleridir.

2.2. Makine Öğrenimi (ML)

Makine öğrenimi, bir veri kümesini en iyi şekilde temsil eden algoritmalar oluşturarak yapay zekanın öğrenme yönüne odaklanmaktadır. Klasik bilgisayar programlarında ise veriler ve oluşturulan algoritma bilgisayara yüklenir ve çıktı elde edilir. Makine öğreniminde ise veri grubu ve çıktılar yapay zekaya yüklenir ve buna uyan algoritma ve özellikler saptanır (şekil1). Ortaya çıkan bu algoritma ile gelecekte veri kümelerinden çıkarım yapılabilecek ve bazı durumların nedenleri bulunabilecektir. Az sayıda değişkene odaklanan geleneksel istatistiksel modellerden farklı olarak makine öğrenimi daha büyük veri kümelerinde çok değişkenli karmaşık yapıları daha hızlı bir şekilde analiz yapabilmektedir (Rajula HSR et al,2020). Makine öğreniminde sorunlar modelleme süreciyle ele alınır. Modelleme süreci tahmin doğruluğuna odaklanır, farklı makine öğrenim yöntemlerinden tahmin doğruluğunu karşılaştırır ve en doğru modeli seçer. İstatistikçilerse basit bir modelle başlarlar ve veriler modelin varsayımlarıyla tutarlı olup olmadığını belirlemek için test edilir. İstatistikte tüm varsayımlar test edildikten ve hiçbir ihlal olmadığından emin olduktan sonra analiz tamamlanmış olur. Makine öğreniminde yüksek hacimli, çeşitliliğe sahip, değere dönüştürülmesi gereken bir bilgi vardır ve bu işlem çok hızlı yapılabilmektedir. İstatistikte ise veriler geriye dönük(retrospektif) veya ileriye dönük (prospektif) olabilir. Makine öğreniminde modelleme üç süreçten oluşur; veri seti

hazırlama, veriye uyan modeli belirleme ve model değerlendirme ve doğrulama (Choi R.Y. et al,2020). Makine öğreniminde, her biri farklı görevleri çözmek için yararlı olan dört öğrenme yöntemi vardır. Bunlar denetimli, denetimsiz, yarı denetimli ve pekiştirmeli öğrenme yöntemleridir (James J,2013). Denetimli makine öğrenimi örüntü tanıma kullanırken, denetimsiz makine öğrenimi kümeleme yöntemi kullanmaktadır. Makine öğrenimi, bunları yaparken algoritma olarak doğrusal regresyon, lojistik regresyon, karar ağaçları ve rastgele ormanları kullanır. Doğrusal regresyon en basit makine öğrenim algoritmasıdır. ML algoritmaları, girdiler ile çıktılar arasındaki ilişkileri istatistiksel olarak modelleyerek tahmin, sınıflandırma veya kümeleme gibi görevleri yerine getirir.



Şekil 1. Klasik bilgisayar ve makine öğrenimi paradigması A. Klasik bilgisayar programlama paradigması B. Makine öğrenimi paradigması

2.3. Derin Öğrenme (DL)

Derin öğrenme, makine öğreniminin alt alanıdır ve yapay sinir ağları (artificial neural networks) üzerine kuruludur. Derin ifadesi, ağı çok katmanlı yapısını (girdi ve çıktı katmanları) ifade eder. Yapay sinir ağı (ANN), biyolojik sinir ağlarını taklit eden makine öğrenim algoritmasıdır (Hastie T et al,2005). Sinir ağlarında girişler, ağırlıklar, eşik(önyargı) ve çıktı vardır. Sinir ağı bir eğitim veri kümesi kullanacak, ardından bu veri

kümelerindeki kalıpları tanıyacak ve veri kümesinin çıktısını tahmin etmek için kullanılabilecek algoritmalar formüle edecek. İşlemde her girdi için bir ağırlık verilir ve çıktının doğrumu yanlış mı olduğuna karar vermek için bir eşik belirlenir. Sinir ağının yapısı girdi, gizli katmanlar ve çıktı şeklindedir. Bütün yapay sinir ağları diğer düğümlerle (aksonlar ve dendritler gibi) bağlantılar aracılığıyla iletişim kuran düğümler içerir. Nöronlar arasında sinapslar, biyolojik sinir ağında nöronların çıktıları birbiriyle ilişkili olduğunda güçlendiği gibi (Hebbian teorisi, birlikte ateşlenen sinirler, birbirine bağlanır kuralını içerir), yapay sinir ağlarındaki düğümler arasındaki bağlantılar da istenen sonucu sağlama yeteneklerine göre ağırlıklandırılır (Hastie T. et al,2009). Yapay sinir ağının temeli algitronudur. Birden fazla algitron bağlandığında, oluşan yapı çok katmanlı algitron algoritması veya yapay sinir ağı olarak adlandırılır. Yapay sinir ağlarında genelde bir giriş düğümü katmanı, bir çıkış düğümü katmanı ve ikisi arasında bir dizi ‘gizli katman’ içerir. Basit yapay sinir ağlarında üç tane kadar gizli katman bulunurken, derin sinir ağlarında onlarca hatta yüzlerce gizli katman bulunmaktadır. Yapay sinir ağları bilgileri ileriye doğru besler. Buna ileri beslemeli sinir ağı denmektedir. Bu ağda giriş düğümü onlarca olabilmekle beraber çıktı düğümü genelde çok daha az ve bir sonuca yönelik olmalıdır. Görüntü tanıma, sınıflama işlemlerinde Konvolüsyonel Sinir Ağları kullanılmaktadır. Aynı zamanda çok katmanlı yapısı nedeniyle büyük veri setleri ve yüksek işlem gücü gerektiren alanlarda (görüntü işleme, doğal dil işleme, genom analizi, ses tanıma vb.) oldukça başarılıdır. Derin öğrenme, veriden özellik çıkarımını otomatikleştirerek, insan müdahalesini en aza indirir. DL modelinin avantajları yanında zorlukları da mevcuttur. DL modelinin gücü, modeli eğitmek için girilen verilerin miktarı ve kalitesi ile ilgilidir. DL sistemlerini güvenilir kılmak için ne kadar verinin gerekli olduğunu tespit etmek zordur, giriş eğitim verilerinin kalitesine hem de görevin niteliğine bağlıdır.

Radyomik veri karakterizasyon algoritmaları kullanarak tıbbi görüntülerden çok sayıda nicel özellik çıkarmaya çalışan bir yöntemdir. Manuel, yarı otomatik veya yapay zeka ile tam otomatik olarak yapılabilir. Radyomiks yazılımının gerçekleştirdiği ana görevler bölge segmentasyonu ve otomatik ölçümler gibi nicelleştirme işlemleridir. Radyografi, ultrason, bilgisayarlı tomografi, manyetik rezonans görüntüleme ve pozitron emisyon tomografisi bir çok görüntüleme yönteminde kullanılabilir. Radyomik, klinik, biyokimyasal ve genetik verilerle kullanıldığında tanı doğruluğunu, prognoz değerlendirmesini ve tedaviye yanıt tahminini arttırabilir. Farklı alanlarda yapılan çeşitli görüntüleme çalışmalarında yayınlanmış ve klinik karar verme sürecini iyileştirdiği vurgulanmıştır (Li Y. et al,2022)

İVF tedavisindeki birçok AI modelindeki en büyük dezavantaj küçük ölçekli, tek merkezli veri setlerinden geliştirilmiş ve test edilmiş olması genelleştirilebilirliğini sınırlamaktadır. Bu çalışmalar klinik ortamlardaki çeşitlilikten yoksun, genellikle homojen hasta popülasyonları ile kontrollü ortamlarda yürütülmektedir. Çeşitli hasta demografileri içeren ve bu modelleri doğrulayan sağlam, çok merkezli, randomize kontrollü çalışmaların yapılmasına ihtiyaç vardır.

Genelleştirebilmek için binlerce eğitim örneği gereklidir. Bu nedenle, nadir hastalıklarda büyük veri kümelerine ulaşamayacağı için model oluşturmak oldukça zordur. Veri kalitesi, azlığı, yanlış etiketlendirme gibi nedenlerden dolayı iyi performans göstermeyen modellerle de karşılaşılabilir. DL yöntemlerinde ayrıca ‘kara kutu’ sorunu bulunmaktadır (Zhou B et al,2016). Algoritmaya girdi sağlanır ve bir çıktı elde edilir, ancak hangi özellikleri tanımladığı, model çıktısını nasıl bilgilendirdiği net değildir. Bu sorunlarda model performansında düşüşe neden olabilecektir.

3. GELENEKSEL İVF TEDAVİSİ

İnvitro fertilizasyon tedavisi, yumurtalıkların uyarılmasıyla oluşturulan oositlerin in vitro ortamda spermle döllenmesini içerir. Oluşturulan embryolar intrauterin boşluğa yerleştirilir. Tipik olarak İVF döngüsü olarak adlandırılan bu süreç yaklaşık iki haftalık bir süreçtir. İVF tedavisine başlamadan önce hastalar infertilite açısından detaylı bir şekilde incelemeye alınır. Kadın infertilitesinde öncelikle over rezervi değerlendirilir. Genellikle adetın üçüncü günü FSH ve östrodiol değerlerine bakılır. Bakılması kolay ve düşük maliyetlidir (Jain T et al,2004). FSH seviyeleri >20 milli-international units/ml ve östrodiol seviyeleri 100 pg/ml ise bu değerler düşük prognozla ilişkilidir (Roberts JE et al,2005). Amh tek başına iyi bir belirleyici olmasa bile aşırı over cevabı açısından oldukça başarılıdır, ancak değerler düşük olduğu durumlarda tedaviden alıkoyucu değildir. Over rezervinin değerlendirilmesi ultrasonla overlerin değerlendirilmesi ve klomifen sitrat testleri ile yanıtların değerlendirilmesi şeklinde de yapılabilir. Bu hastalarda erkek fertilitesi açısından semen analizi, tubal faktörlerin değerlendirilmesi için de histeresalfingografi gibi yöntemler kullanılmaktadır. İVF öncesinde ovulasyon indüksiyonu ve aşılama tedavisinin denenmesi tedavi aşamalarının ilk basamaklarıdır. Bunlardan yanıt alınmadığında İVF protokolüne geçilmektedir. İVF protokolü içinde infertilite incelemelerindeki sonuçlara göre hastalara ivf protokolleri oluşturulmaktadır.

Hastaların özelliklerine göre kontrollü over stimülasyonu yapılmaktadır.

Over stimülasyonu, iyi ovarian yanıt beklenen hastalarda GnRH agonisti veya GnRH antagonistleri ile uzun protokol uygulanır. Uzun protokolda gonadotropinler düşük doz verilir. Uzun protokolda iki aşama vardır. Öncelikle hipofiz baskılanır, ardından over stimüle edilir.

Kötü ovarian yanıt beklenen hastalarda kısa protokol uygulanır. Stimülasyon insan menapozal homogonadotropinler (hMG) ve FSH ile sağlanır. Kısa protokol için GnRH antagonistleri tercih edilir. Çoğu protokol eksojen günlük FSH enjeksiyonları içerir. Gonadotropinler erken LH elevasyonunu engellemek için kullanılmaktadır. Esnek bir protokolda GnRH antagonisti folikül yaklaşık 14mm olduğunda uygulanır. Sabit protokolda genellikle döngünün altıncı gününde uygulanır. Kısa protokolda gonadotropinler maksimum doz verilir.

Over stimülasyonu için, FSH ve hMG veya her ikisi birden foliküler uyarımı sağlamak için 150-450 internationalunite/ gün dozda uygulanır (Coomarasamy A et al,2008). FSH ve hMG dozları folikül gelişimine ve östradiol dozlarına göre ayarlanır. ‘Adım aşağı’ protokolünde gonadotropin başlangıç dozu yüksek olup sonrasında kademeli olarak düşürülmektedir. ‘Adım yukarı’ protokolünde ise gonadotropin dozları başlangıçta düşüktür yanıtı bağlı kademeli olarak arttırılmaktadır.

Ovulasyonu tetiklemek için idrar veya rekombinant HCG ve /veya GnRH agonistleri kullanılır. GnRH agonistleri taze embriyo transferi düşünülen durumlarda tercih edilmez. HCG ile uzun yarı ömrü ve OHSS riski taşıması sorun oluşturabilmektedir.

Oosit alımı ovulasyon tetikleyicisi uygulamasının yaklaşık 34-36. saatinde transvajinal ultrason eşliğinde folikül aspirasyonu ile gerçekleştirilir. Transvajinal ultrason eşliğinde vajinal yan duvardan girilen bir iğne yardımıyla tüm görünür foliküller çökene kadar teker teker aspire edilir.

İn vitro döllenmeyi sağlamak için aspire edilen ovum ve spermatozoa küçük bir kültür ortamında karıştırılır. Normal spermle IVF sonrası toplam döllenme başarısızlığı oranı yüzde 4 ila 16’ dır. Bu bireylerde tekrarlayan başarısızlık oranı yüzde 30

civarındadır (Barlow P et al,1990). Şiddetli erkek faktörü olan hastalarda mikromanüplasyon ve intrastoplazmik sperm enjeksiyonları (ICS) yapılmaktadır.

Oositin döllemesi, inseminasyondan veya ICS' den yaklaşık 18 saat sonra zigot içinde 2 tane pronükleinin görülmesi ile konur. Dölleme sonrası, embiryonun blastomerleri her 12 veya 14 saatte bir bölünür, böylece embiryo 72 saat sonrasında sekiz hücreye dönüşür. İkinci ve dördüncü günler arasındaki embiryo 'bölünme aşaması embiryo' olarak adlandırılır. Blastosist aşamasına, yumurtanın alınmasından yaklaşık 5 gün sonra ulaşılır ve implantasyonun yumurtanın alınmasından yaklaşık 7 gün sonra gerçekleşmesi beklenir, bu nedenle transfer bu tarihten önce yapılmalıdır.

“Kuluçka” embiryonun genişleyerek zona pellucida'yı kırması ve endometriyumun yüzeyine yerleşmesi için geçirdiği doğal bir süreçtir. “Yardımlı Kuluçka” zona pellucida' nın mekanik veya kimyasal olarak açılmasıyla, embiryonun yaklaşık üç gün sonra blastosist aşamasında kuluçkanın tamamlanmasına yardımcı olan bir laboratuvar prosedürüdür. Bu prosedür, kötü prognozlu seçilmiş vakalarda (yaşlı kadınlar, kötü embiryo kalitesi ve ≥ 2 başarısız IVF döngüsü) implantasyon oranını arttırabilir, faydası tartışmalıdır (Brigham,2014).

PGT-A (anöploidi için implantasyon öncesi genetik test), embiryolarda kromozomal anöploidiyi tespit etmek, transfer edilecek embiryo'yu belirlemek ve transfer edilecek tek embiryonun bulunması ile çoğul gebelik oranlarını azaltmak için yaygın olarak kullanılır (Forman EJ et al,2014). Anöploidi tespiti için PGT-A, monogenik (tek gen) için PGT-M, polijenik bozukluklar için PGT- P, yapısal yeniden düzenlemeler için implantasyon öncesi genetik test PGT- SR yapılır. Gelişim aşaması blastositte döllemeden sonra ki beşinci ve altıncı gününde yaklaşık 100 adet hücre bulunur. Lazer, asit tyrode

çözültisi veya keskin cam iğne ile zona pellucida' da küçük bir açıklık meydana getirilir. PGT, küçük bir pipet yardımı ile blastosist aşamasında, embiryonik DNA'nın embiryonik iç hücre kütlelerinin trofektoderm olarak farklılaştığı yapıdan kısaca trofektodermde ki hücrelerden alınır. Fetoplacental ünitenin bozulmaması için beş ila sekiz hücre alınır. PGT-A işlemi, gebelik kaybı oranını azaltmak ve canlı doğum oranını arttırmak için yaygınlaştı, bu nedenle PGT-A uygulaması rutin protokole girmemiştir ve canlı doğum oranını düşürebilir (Paulson RJ et al,2020). İleri yaş hastalarda anöplöid embiryo oranı yüksek olduğu için PGT-A'dan fayda görebilirler. Devam eden gebelik ve canlı doğum oranları, euploid transfer edilmişler de test edilmemiş blastositlerden transfer edilenlere göre daha yüksektir (Cheng X et al,2022).

Yüksek implantasyon şansı olan embiryolar, morfolojik kriterlere ve varsa PGT-A testlerine göre seçilir. Bölünme aşamasındaki embiryolar yaklaşık 72 saat sonra uterusu aktarılır (dört ila sekiz hücreli, bölünme aşamasında). Blastosist evresi embiryoları beşinci günde transfer edilir. Transferi geciktirmek kaliteli embiryonun seçimine olanak tanır. Blastosist evresi transferi PGT-A yapılmasına olanak sağladığı gibi tek blastosit yerleştirilmesi ile çoğul gebelik gelişmesini önler. Uterusa embiryonun yerleştirilmesi, embiryonun taze veya dondurulmuş embiryo olmasına göre farklı tedavi protokolleri ile yapılmaktadır. Embiryo yerleştirme doğal döngü, yapay (ilaçlı) döngü, modifiye edilmiş doğal ve yapay döngü olarak yapılabilir. Tedavi protokolü düzenlenirken hasta ve uygulama özelliklerine göre protokoller belirlenmektedir. Yaş, OHSS riski, İVF sayısı vb. gibi özellikler değerlendirilir.

4. YAPAY ZEKA DESTEĞİ UYGULANABİLECEK İVF UYGULAMALARI

İnfertil hastalarda İVF tedavisi tek ve son seçenek olması ve başarı oranlarının belirli bir seviyede kalması yeni çözüm arayışlarını tetiklemektedir. Yapay zeka modellerinin büyük veri kümelerini analiz yeteneği, yüksek çözünürlüklü görsel kayıtlarla kaliteli oosit, sperm, embiryo seçimi gibi olanaklar optimizasyon şansı sunarak başarı oranlarını yükseltebilir. İVF tedavisinde ovulasyon indüksiyonu protokollerinin kişiselleştirilmesi, embiryo seçimi, sperm sınıflandırılması ve seçimi, oosit kalitesinin değerlendirilmesi ve seçimi, genetik verilerin entegrasyonu gibi uygulamalarla yapay zeka desteğinden faydalanılabilir. Ayrıca kalite kontrol ve temel performans göstergelerinin izlenmesi, prosedüre bağlılık ve iş akışı optimizasyonu sağlayan algoritmalarla verimlilik artışı sağlanabilir. Arızaların temel neden analizini tanımlama, sürekli iyileştirme algoritmaları da sürece destek sağlayabilir.

4.1. Yapay zeka destekli kişiye özgü over stimülasyon protokolü

İVF süreçlerinde elde edilen oosit kalitesini yükselttikleri için over stimülasyon protokolleri büyük önem taşımaktadır (Alper M. et al, 2017). Gonadotropinlerle overlerin stimülasyonu çoklu folikül oluşumunu sağlar. Over stimülasyonunun yaş, over rezervi, hormon profili gibi hasta özelliklerine bağlı düzenlenmesi başarı oranları açısından önem taşımaya başlamıştır. Yaş ve over rezervlerine göre hastalar daha farklı protokollere ihtiyaç duyabilirler. Oosit stimülasyonu protokollerinin overin aşırı hipersitimülasyonu, düşük oosit kalitesi ve daha düşük İVF başarı oranları gibi zorlukları vardır. Bu zorlukları yapay zeka ile entegre edilmiş geniş sayıdaki tedavi protokolleri ve sonuçlarının büyük veri kümeleri ile analiz edildiği algoritmalarla daha iyi ve başarı şansı yüksek kişiye özgü

tedavi protokolleri üretilebilir. Yapay zeka büyük veri kümeleri içindeki kalıpları ve korelasyonları belirleyerek geleneksel analizden farklı öngörülerde bulunabilirler (Mann M et al,2021). Hastanın yaşı, over rezervi, vücut kitle indeksi ve amh verilerinin dahil edildiği faktörlere göre gonadotropin dozları ve zamanlamanın ayarlandığı tedavi protokolleri ve başarı oranları tahmin algoritmaları yapılabilir. Bunlarda klinik sonuçlarda artışla sonuçlanabilir. Bu protokolleri dinamik yaklaşım eklenerek yanıtlara göre tedavi protokolleri değiştirilebilir, OHSS riskini azaltabilir (Hariton E et al,2023).

4.2. Yapay zeka destekli oosit değerlendirilmesi ve seçimi

Oosit kalitesi, embiryo implantasyonu ve canlı gebelik gelişimi için kritik önem taşımaktadır. Metafaz 2 safasındaki oositlerin özelliklerinin gebelik elde etme başarısı ile paralel olduğu gözlenmiştir (Maziotis E. et al,2020). Geleneksel oosit kalitesi değerlendirme yöntemi mikroskop altında morfolojik kriterlere dayanır; örneğin zona pellusidanın, sitoplazmanın, polar cisimin görünümü, germinal vezikülün varlığının tespiti gibi (Balaban B et al,2022). Oositlerin doğru değerlendirilmesi, başarılı dölleme, embiryo gelişimi ve gebelik elde edilmesi açısından önemlidir. MII oosit, ikinci mayoz bölünmenin metafaz II'deki oositidir. Mikroskobik görüntüde, sitoplazmayı çevreleyen zona pellusida, izole ilk kutup gövdesi ve perivitelline alan varlığı incelenir. İlk kutup gövdesi görünümü sadece bu aşama için tipiktir. Dölleme için bu oositler kullanılmalıdır. Birçok ivf merkezinde bu değerlendirme, kliniklerdeki embiryologlar tarafından yapılmaktadır. Bu da embiryoloğun mesleki deneyimine bağlı olarak değişmektedir. Yapay zeka modelleri, oositlerin yüksek çözünürlüklü görüntülerine dayalı analizler yaparak oosit kalitesi değerlendirilmesinde daha güçlü olanaklar sağlayabilir (Letterie G. et al, 2022). AI ile desteklenmiş görüntü analiz teknikleri ile manuel

değerlendirmeye ayırt edilemeyen oosit kalitesiyle ilişkili ince ayrıntılar tespit edilebilir. Yapay zeka algoritmaları oositin homojenliğini, zona pellucidanın bütünlüğünü, sitoplazmik yapıyı ve vakuollerin değerlendirilmesini daha nitelikli olarak yapabilir. Bu yapılar oosit kalitesini göstermektedirler. Yapay zeka modelleri ile objektiviteden uzaklaşmış daha fazla standardize edilmiş algoritma modelleri oluşturulabilir (Si K. et al,2023). Yüksek çözünürlüklü morfolojik görüntülerin entegre edildiği AI modelleri ile kaliteli ovum seçiminde başarı oranları arttırılabilir, hızlandırılmış görüntüleme yoluyla oosit gelişimin sürekli izlenmesi sağlanabilir. Bu yöntemler de oosit gelişim potansiyelini tahmin etmek için dinamik bilgiler elde etmemizi sağlar (Bhide P. et al,2024).

4.3. Yapay zeka destekli Sperm değerlendirilmesi ve seçimi

Geleneksel sperm seçim yöntemleri, manuel değerlendirme ile mikroskopik olarak hareketlilik ve morfolojinin değerlendirilmesi gibi temel tekniklere dayanmaktadır (Dias T.R. et al,2019). Bu değerlendirmeler kişiye bağımlı ve öznelidir. Ayrıca zaman alıcıdır ve her zaman gebelik potansiyelini öngöremeyebilir.

Sperm seçiminde geleneksel yöntemin verimliliğini arttırmaya yönelik modeller geliştirilebilir.

Erkek kısırlığındaki en kritik sorunlardan biri, seminal yolun farklı bölümlerinin (epididimler, prostat ve seminal veziküller) normal veya patolojik durumunu, semen kalitesini (motilite, lökositospermi, sperm DNA parçalanması, reaktif oksijen türleri gibi) değerlendirmektir. Bu değerlendirme radyomikle invaziv yöntemler olmadan yapılabilir. Semen analizi son yirmibeş senedir öznellikten uzaklaştırılabilmesi için bilgisayar destekli semen analizi (CASA) ile yapılmaktadır. Ancak CASA yöntemi ile sperm konsantrasyonu ve morfolojideki

çok çeşitlilikten dolayı kullanımı kısıtlı kalmıştır (Finelli R. et al,2021). Son dönemlerde CASA makinesine sperm hareketlilik kalıplarını yükleyerek AI modeli ile entegre edilmiştir (Goodson SG. et al,2017).

Morfolojik yapıdaki farklılıkları tanıyabilme ve hareketlilik değerlendirmelerinde daha önceki birçok sperm hareketliliği görüntülerinin ve videolarının yapay zekaya entegre modelleri ile karşılaştırarak daha kaliteli sperm elde edebilme şansı oluşabilir. Son dönemlerde yapılan çalışmalar semen analizinde hareket değerlendirilmesinin yapay zekanın geleneksel yöntemle göre daha başarılı olabileceği, hızlı ve düşük maliyetle iyi bir alternatif olabileceğini göstermektedir (Ottl S. et al,2022). Sperm görüntülerindeki küçük farklar, yapay zeka tabanlı modellerle daha iyi yakalanabilir. Derin öğrenme algoritmaları, sperm hareketinin yüksek çözünürlüklü video görüntülerini analiz ederek hız, doğrusal ve yanal baş yer değiştirme gibi hareketlilik parametrelerini daha başarılı değerlendirebilir (Shahali S. et al,2024). Yapay zeka, sperm kalitesinin daha hassas ve objektif bir değerlendirmesini sağlayarak, döllenme için en iyi spermi seçme şansının arttırabilir. Özellikle erkek infertilitesi vakalarında en iyi spermin seçilmesi oldukça önemlidir ve bu konuda çok yardımcı olabilir. Bu yardım başarılı döllenme olasılığını arttırdığı gibi embriyo kalitesini de arttırmaktadır. Yakın zamanda yapılan bir çalışma ile sperm DNA parçalanmasını tespit edebilme ve bu sayede kaliteli sperm seçimi ile gebelik kaybını azaltma amaçlanmaktadır (Mc Callum et al,2019).

AI, sperm hareketliliğini ve morfolojiyi sınıflandırmanın yanı sıra leptin, çinko ve kromozomal bozuklukları tahmin etme potansiyeline sahiptir. Sperm kalitesini etkileyebilecek yaşam kalitesi ve faktörleri konusunda da geniş veri kümelerini kullanarak doğru analizler ve öngörüler sunabilir (Girela JL. et al,2013).

4.4. Yapay zeka destekli Embiryo seçimi

İVF sürecinde döllenme sonrası 14-18. saatlerde döllenmiş yumurtaların sayısı ve kalitesi çok önemlidir. Normal olarak döllenmiş oositin sitoplazmasında 2 pronüklei varlığı olmalıdır, biri maternal biri paternal kaynaklıdır. Bu yapıdan farklı gelişmiş oositler anormal döllenmiş oositler olup gebelik kaybı, genetik anormallikler ve gelişimsel bozukluklarla beraber olmasına rağmen hala literatürde canlı gebelik şansı bulunmaktadır (Capalbo A. et al,2017). Bu dönemlerde bazı boyut ve şekle sahip döllenmiş oosit seçimleri ile canlı gebelik elde edilmesi arasındaki ilişkinin analizini yapan çalışmalara devam edilmektedir.

Embriyoların değerlendirilmesi sırasında, embriyologların insan faktörünü içeren değişkenlik ve tutarsızlık risklerini en aza indirmek için modeller geliştirilmeye çalışılmaktadır. Yardımcı üreme alanındaki derin öğrenme modeli yapay sinir ağları, belirli durumlarla ilgili büyük statik veri kümeleri ile eğitilirler (Hosravi P. et al,2019). Bu ağlar embiryo puanlama ve karar vermede tutarlılık açısından geleneksel yöntemlerden daha başarılı ve embriyologların karar vermesine yardımcı olabilecek algoritma modelleri oluşturabilirler. Bu modeller, morfolojik verileri, zaman atlamalı görüntüleri ve genetik bilgileri içeren verilerle bütünsel bir değerlendirme ve karar verme sürecinde etkili olabilecek algoritmalar oluşturulmasına yardımcı olabilirler. Başarılı implantasyon ve gelişim için en yüksek potansiyele sahip embriyoları belirleyerek implantasyon oranlarını arttırabilir ve başarılı bir hamilelik elde etmeyi sağlayabilir (Fitz et al,2021). Boarman ve ark bununla ilgili bir çalışmada insan performansını aşan düzeyde verimlilik tespit etmişlerdir (Boarman C.L. et al,2020).

Embriyo seçimi sırasında, morfolojik görsel değerlendirme hücre sayısı, simetrisi, bölünmesi statik görüntüler üzerinden konvansiyonel sinir ağı (CNN) ile yapılabilir. Bu değerlendirme objektif, tutarlı, embriyologlardan bağımsız ve canlı embriyo seçimi ihtimalini arttırır.

Geleneksel yöntemle embriyo gelişim aşamaları takip edilmektedir. En iyi embriyoyu seçerken embriyologlar embriyoyu inkübatörden genellikle birden fazla çıkartabilirler. Bu işlemde embriyo kalitesinde düşmeye yol açabilir. Zaman aralıklı görüntüleme sistemi entegre yapay zeka modeli (örn., Embryoscope, Eeva) ile embriyo gelişim aşamaları takip edilebilir ve inkübatörden aralıklı çıkarma işlemi devre dışı bırakabilir. Embriyo gelişiminin sürekli izlenmesi, ince gözden kaçabilecek küçük değişikliklerin ve dinamik davranışların tespitini sağlayabilir ve implantasyon ihtimali en yüksek embriyoyu tespit etme şansını arttırabilir. Dinamik zaman aralıklı görüntüleme verileri ve bunlarla paralel sonuçların yapay zeka destekli algoritmalarla kaliteli embriyo belirleme kriterlerinin geliştirilebileceği düşüncesi vardır. Genetik, morfolojik ve gelişimsel değişikliklerin dataları ile oluşturulacak AI modelleri ile en verimli embriyoların seçiminin yapılabilmesi sağlanabilir.

Embryonun implantasyonu sırasında aneuploidi, implantasyon başarısızlığının, gebelik kaybının ve konjenital anomalilerin başlıca nedenidir (Schaeffer ve ark,2018). Tüp bebek uygulaması sırasında, embriyoların genetik yapısını ve transfer sırasında euploid embriyoyu belirleyebilmek için preimplantasyon genetik testi (PGT-A) kullanılır (Greco et al,2020). PGT-A işleminin biopsi olması nedeniyle travmatik bir prosüdür olması ve buna bağlı olarak hasar verme potansiyeli taşıması en önemli dezavantajıdır (Rubino et al,2020). Bu yüzden daha az invaziv yöntemlerin geliştirilmesi için güçlü bir istek vardır. Yapay zeka tabanlı bir uygulamada statik 2 boyutlu görüntüleri kullanarak embriyoların plöidilerini tespit etmeye

yönelik çalışmalar vardır. Prospektif bir dizi embiryo görüntüsünün daha önceden tüp bebek merkezlerinden toplanmış görüntülerle karşılaştırarak biopsi gerekmeden plöidi tahmini yapmaya yarayan yapay zeka programı oluşturulmuştur (Chavez – Badiola et al, 2020). Bu uygulama standart mikroskoba ve zaman atlamalı kameralara göre tasarlanmıştır. 5. Gün embiryo ve 6. Gün embiryo genetik AI değerlendirmede plöidi yanında mozaizm tahmin etme doğruluğu da saptanmıştır. Bu çalışmada 5.gün embiryo görüntüleri ve PGT- A görüntüleri üzerinde eğitilmiş yapay zeka modelinin, 5.gün ve 6.günde blastosist görüntülerinde plöidi durumunu öngördüğünü bulmuştur. Euploid embiryoaları tahmin etme oranları %75-95 arası değişmektedir. Embiryo plöidi durumunun hasta özellikleri anne yaşı, amh değeri, baba sperm özellikleri ile plöidi durumunu birlikte yapay sinir ağları ve çok katmanlı sinir ağları ile başarı oranlarını öngörmeye yönelik modeller geliştirmişlerdir. (Jiang V.S. et al, 2023). Bu çalışmanın embiryoda euplöidi ve aneplöidiyi belirlemede faydalı bulunmuştur. İnvazif olmayan embiryo seçim şansı önemli bir kazanım olabilir.

Transfer için embiryo seçiminde yapay zeka algoritmaları oluşturulmuştur. Fitz ve ark. yüksek deneyimli embiryologların yapay zeka algoritmalarıyla birlikte ve olmadan 5. Gün euploidi blastositleri kullanarak oluşturulan embiryoaların gebelik oranları karşılaştırmışlardır. Yapay zeka algoritmaları ile yapılan uygulamalarda başarı oranları daha yüksek bulunmuştur. Algoritma ile yapılan uygulamalarda %78,5 oranında embiryoyu seçtiği, tek başına embiryolog tarafından yapılan uygulamalarda bu oran %65,5 olmuştur (Fitz et al,2021) Uygulama ile başarı oranları %11,1 artmıştır. Daha az deneyimli embiryologlarla yapılacak çalışmada başarı oranları daha fazla artabilecektir.

4.5. Yapay zeka destekli İntrasitoplazmik sperm enjeksiyonu

İntrasitoplazmik sperm enjeksiyonu, İvf de kullanılan spermin ovumun içine enjekte edilmesi yöntemidir. Yöntemin zorluğu çok küçük yapıların, birbiri içine zarar vermeden, doğru şekilde enjekte edilmesinden kaynaklanmaktadır. Derin öğrenme modellerinin insan oositlerinin en uygun yönünü doğru bir şekilde belirlemek için kullanılabilmektedir (Saadat M. et al,2018). Yapılan bir çalışmada yapay sinir ağlarının olgun oositlerde kutup cisimlerinin yerini belirleyebilme açısından eğitildiler ve %99 oranında başarıyla yerlerini tespit edebildikleri bulundu (Jiang V.S. et al,2023). Lazer destekli kuluçka yönteminin güvenli yapılmasına olanak tanıyan koşulların belirlenmesinde ve embriyoya en az hasar vererek yapılabilmesine yardımcı olması amaçlanmaktadır. Jiang ve ark lazer uygulanabilecek yeri %99,5 oranla CNN-AH modeliyle tespit edebilmiştir. Mikromanüpülasyon uygulamalarında katkıda bulunabilecektir.

4.6. Yapay zeka destekli tedavi protokolleri ve iş akış denetim algoritmaları

İVF tedavisinde zamanlama başarılı sonuçlar almak açısından oldukça önemlidir. Yapay zeka algoritmaları ile tedavi protokolleri ve işlemler için doğru zamanlama yapılabilir. Dinamik ve kendi kendini optimize etmeye koşullandırılmış zamanlama uygulamaları modellenabilir. İş akışı denetim algoritmaları ile açıkların yakalanması sağlanabilir. Daha önceki tedavi protokolleri, iş akışı seyirleri ile başarı sonuçları yapay zeka modelleri ile analiz edilerek daha iyi uygulama ve protokollere ulaşılabilir. Çevre koşulları, laboratuvar faaliyetleri takip edilebilir ve fonksiyonları optimize edilebilir. Oosit alımı, dölleme ve embriyo transferi gibi kritik prosedürlerin gereksiz gecikme yaşamadan yapılabilme olanağı sağlar (Pavlovic Z. et al,

2024). Gametlerin ve embiriyoların zamanında alınması, en iyi şekilde korunmalarını, kalitelerini ve canlılıklarını korumalarına yardım eder. Bu şekilde daha yüksek döllenme oranlarına, daha iyi embiryo gelişimine ve İVF döngülerinde başarı oranlarını artmasına neden olabilir (Khan H.L. et al,2023). Ayrıca laboratuvar ekipmanları, teçhizatların takibi, çalışanların iş bölümü gibi modeller düzen ve takip işini yapmaya yardım edebilir. Kalite kontrol standartlarını korumak İVF başarılarını arttırmaya ve korumaya yardım edebilir. Kalite kontrol standartlarının en iyi göstergeleri olan döllenme oranları, blastosit oluşum oranları ve klinik gebelik oranları ile takip edilebilir (Fabozzi G. et al,2020)

Performans göstergelerinde azalma olduğunda, yapay zeka oosit toplama veya gamet seçiminde yanlış bir adımı tespit edip farklı bir bakış sağlayabilir. Sistemin kendi otokontrolünü yaparak yeni seçeneklere ulaşmayı kolaylaştırabilir. AI ile laboratuvar koşullarının ve prosedürlerinin takibi süreci optimize ederek başarı oranlarını yükseltebilir (Tamir S.,2023).

5. YAPAY ZEKANIN İVF TEDAVİSİNDEKİ ENTEGRASYONUNDAKİ GÜNCEL SORUNLAR

Entegrasyondaki en büyük sorun şu ana kadar olan yapılan çalışmaların küçük ölçekli olmasıdır. Daha büyük, çok merkezli ve randomize kontrollü çalışmalarla yeni çalışma modelleri oluşturarak standardize edilmesi gerekmektedir. Aynı zamanda veri girişlerinin ve raporlarının standartlaştırılmış yapılması sonuçların doğru toplanmasına yardım edecektir. Buralardaki farklılıklar çalışmalar arasındaki farklılıklara yol açabilmektedir. Standardize edilmiş veri girişi ve protokoller büyük ölçekli çalışmalara fırsat vererek başarı oranlarındaki değişikliği anlamamıza yardım edecektir. Yapay zekadaki bir diğer sıkıntı hasta veri gizliliği ve güvenliğine dair problemlerdir.

Yapay zeka uygulamalarındaki sistem, büyük veri kümeleri gerektiren sistemler olduğu için veri gizliliği ve güvenliği problem olarak durmaktadır, bu yüzden yapay zekanın ivf uygulamalarına entegrasyonu için sağlam şifreleme yöntemleri, güvenli depolama ve sınırlı erişim gibi kontrol sistemi içermesi gerekmektedir. Diğer taraftan yapay zekada ‘kara kutu’ problemi bulunmaktadır. Kara kutu problemi, karar verme süreçleri ve algoritmalarının klinisyenler ve hastalar tarafından kolayca anlaşılamamasıdır. Bu bilinmemelik uygulama doğruluğunu sorgulamamıza neden olabilecektir. Uygulamanın başarısızlığı noktasında sorumluluğun kimde olduğu ve hasta onayı gibi problemler de ciddi sorunlar olarak önümüzde durmaktadır.

6. SONUÇ

Yapay zeka uygulamaları invitro fertilizasyon tedavisine veriye dayalı, objektif ve standardize edilmiş uygulamalarla önemli katkılar sunabilme kapasitesine sahiptir. Ovum, sperm ve embriyo seçiminin daha kaliteli yaparak ivf tedavisindeki gebelik oranlarını, implantasyon oranlarını arttırabilir. Erkek infertilitesinde ve ileri yaş gebeliklerde genetik seçim konusunda sağlayabileceği noninvaziv tedavi seçenekleri ile klinisyenlere büyük yardımlar yapabilir. Kişiye özel tedavi protokolleri oluşturarak kötü prognozlu hastalarda gebelik gelişim oranlarına katkıda bulunabilir.

Ancak şu döneme kadar yapılan çalışmaların küçük ölçekli, tek merkezli ve izole hasta popülasyonlarında yapılmış olması sonuçları yetersiz kılmaktadır. Büyük ölçekli, çok merkezli, randomize kontrollü çalışmalara ve standardize edilmiş uygulamalara ihtiyaç bulunmaktadır. Hasta gizliliği, onayı ve başarısızlık sonrasında sorumluluğun kimde olduğu gibi etik sorunların da çözülmesi gerekmektedir.

KAYNAKÇA

- Alper, M. M., & Fauser, B. C. (2017). Ovarian stimulation protocols for IVF: is more better than less?. *Reproductive biomedicine online*, 34(4), 345-353.
- Balaban, B., Keles, I., & Ebner, T. (2022). Morphological assessment of oocyte quality. *Manual of Oocyte Retrieval and Preparation in Human Assisted Reproduction*, 85.
- Barlow, P., Englert, Y., Puissant, F., Lejeune, B., Delvigne, A., Van Rysselberge, M., & Leroy, F. (1990). Fertilization failure in IVF: why and what next?. *Human reproduction*, 5(4), 451-456.
- Bhide, P., Chan, D. Y., Lanz, D., Alqawasmeh, O., Barry, E., Baxter, D., ... & Thangaratinam, S. (2024). Clinical effectiveness and safety of time-lapse imaging systems for embryo incubation and selection in in-vitro fertilisation treatment (TILT): a multicentre, three-parallel-group, double-blind, randomised controlled trial. *The Lancet*, 404(10449), 256-265.
- Bormann, C. L., Thirumalaraju, P., Kanakasabapathy, M. K., Kandula, H., Souter, I., Dimitriadis, I., ... & Shafiee, H. (2020). Consistency and objectivity of automated embryo assessments using deep neural networks. *Fertility and sterility*, 113(4), 781-787.
- Brigham, A. C. O. Medical Policy Infertility Services/Assisted Reproductive Services.
- Forman, E. J., Hong, K. H., Franasiak, J. M., & Scott Jr, R. T. (2014). Obstetrical and neonatal outcomes from the BEST Trial: single embryo transfer with aneuploidy screening improves outcomes after in vitro fertilization without compromising delivery rates. *Obstetrical & Gynecological Survey*, 69(12), 742-744.

- Capalbo, A., Treff, N., Cimadomo, D., Tao, X., Ferrero, S., Vaiarelli, A., ... & Rienzi, L. (2017). Abnormally fertilized oocytes can result in healthy live births: improved genetic technologies for preimplantation genetic testing can be used to rescue viable embryos in in vitro fertilization cycles. *Fertility and sterility*, 108(6), 1007-1015.
- Chavez-Badiola, A., Flores-Saiffe-Farías, A., Mendizabal-Ruiz, G., Drakeley, A. J., & Cohen, J. (2020). Embryo Ranking Intelligent Classification Algorithm (ERICA): artificial intelligence clinical assistant predicting embryo ploidy and implantation. *Reproductive biomedicine online*, 41(4), 585-593.
- Cheng, X., Zhang, Y., Deng, H., Feng, Y., Chong, W., Hai, Y., ... & Fang, F. (2022). Preimplantation genetic testing for aneuploidy with comprehensive chromosome screening in patients undergoing in vitro fertilization: a systematic review and meta-analysis. *Obstetrics & Gynecology*, 140(5), 769-777.
- Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Makine öğrenimine, sinir ağlarına ve derin öğrenmeye giriş. Transl Vis Bilim Teknolojisi. 2020;9:14. doi: 10.1167/tvst.9.2.14.
- Coomarasamy, A., Afnan, M., Cheema, D., van der Veen, F., Bossuyt, P. M., & van Wely, M. (2008). Urinary hMG versus recombinant FSH for controlled ovarian hyperstimulation following an agonist long down-regulation protocol in IVF or ICSI treatment: a systematic review and meta-analysis. *Human Reproduction*, 23(2), 310-315.
- Dias, T. R., Cho, C. L., & Agarwal, A. (2019). Sperm assessment: Traditional approaches and their indicative value. In *In vitro fertilization: A textbook of current and emerging*

methods and devices (pp. 249-263). Cham: Springer International Publishing.

Fabozzi, G., Cimadomo, D., Maggiulli, R., Vaiarelli, A., Ubaldi, F. M., & Rienzi, L. (2020).

Which key performance indicators are most effective in evaluating and managing an in vitro fertilization laboratory?. *Fertility and sterility*, 114(1), 9-15.

Finelli, R., Leisegang, K., Tumallapalli, S., Henkel, R., & Agarwal, A. (2021). The validity and reliability of computer-aided semen analyzers in performing semen analysis: a systematic review. *Translational Andrology and Urology*, 10(7), 3069.

Fitz, V. W., Kanakasabapathy, M. K., Thirumalaraju, P., Kandula, H., Ramirez, L. B., Boehnlein, L., ... & Shafiee, H. (2021). Should there be an “AI” in TEAM? Embryologists selection of high implantation potential embryos improves with the aid of an artificial intelligence algorithm. *Journal of Assisted Reproduction and Genetics*, 38(10), 2663-2670.

Girela, J. L., Gil, D., Johnsson, M., Gomez-Torres, M. J., & De Juan, J. (2013). Semen parameters can be predicted from environmental factors and lifestyle using artificial intelligence methods. *Biology of reproduction*, 88(4), 99-1.

Graham, M. E., Jelin, A., Hoon Jr, A. H., Wilms Floet, A. M., Levey, E., & Graham, E. M. (2023). Assisted reproductive technology: Short-and long-term outcomes. *Developmental Medicine & Child Neurology*, 65(1), 38-49.

Greco, E., Litwicka, K., Minasi, M. G., Cursio, E., Greco, P. F., & Barillari, P. (2020). Preimplantation genetic testing:

where we are today. *International journal of molecular sciences*, 21(12), 4381.

Goodson, S. G., White, S., Stevans, A. M., Bhat, S., Kao, C. Y., Jaworski, S., ... & O'Brien, D. A. (2017). CASAnova: a multiclass support vector machine model for the classification of human sperm motility patterns. *Biology of reproduction*, 97(5), 698-708.

Hajirasouliha, I. (2019). Deep learning enables robust assessment and selection of human blastocysts after in vitro fertilization. *NPJ digital medicine*, 2(1), 21.

Hariton, E., Pavlovic, Z., Fanton, M., & Jiang, V. S. (2023). Applications of artificial intelligence in ovarian stimulation: a tool for improving efficiency and outcomes. *Fertility and sterility*, 120(1), 8-16.

Hastie T, Tibshirani R ve Friedman JH. *İstatistiksel Öğrenmenin Unsurları: Veri Madenciliği, Çıkarım ve Tahmin*. 2. baskı. New York, NY: Springer; 2009.

Hebb DO. Animal and physiological psychology. *Annu Rev Psychol.* 1950; 1: 173–188. 10.1146/annurev.ps.01.020150.001133.

Jain, T., Soules, M. R., & Collins, J. A. (2004). Comparison of basal follicle-stimulating hormone versus the clomiphene citrate challenge test for ovarian reserve screening. *Fertility and sterility*, 82(1), 180-185.

James, G. (2013). An introduction to statistical learning with applications in R.

Jiang, V. S., Kandula, H., Thirumalaraju, P., Kanakasabapathy, M. K., Cherouveim, P., Souter, I., ... & Shafiee, H. (2023). The use of voting ensembles to improve the accuracy of deep neural networks as a non-invasive method to predict

- embryo ploidy status. *Journal of assisted reproduction and genetics*, 40(2), 301-308.
- Khan, H. L., Khan, S., Bhatti, S., & Abbas, S. (2023). Role of artificial intelligence in quality assurance in ART: a review. *Fertility & Reproduction*, 5(01), 1-7.
- Khosravi, P., Kazemi, E., Zhan, Q., Malmsten, J. E., Toschi, M., Zisimopoulos, P., ... &
- Rubino, P., Tapia, L., de Assin Alonso, R. R., Mazmanian, K., Guan, L., Dearden, L., ... & Tan, T. (2020). Trophoctoderm biopsy protocols can affect clinical outcomes: time to focus on the blastocyst biopsy technique. *Fertility and sterility*, 113(5), 981-989.
- LeCun Y, Bengio Y, Hinton G. Derin öğrenme. *Doğa*. 2015; 521: 436–444. 10.1038/doğa14539
- Letterie, G., MacDonald, A., & Shi, Z. (2022). An artificial intelligence platform to optimize workflow during ovarian stimulation and IVF: process improvement and outcome-based predictions. *Reproductive biomedicine online*, 44(2), 254-260.
- Li, Y., Wei, D., Liu, X., Fan, X., Wang, K., Li, S., ... & Wang, Y. (2022). Molecular subtyping of diffuse gliomas using magnetic resonance imaging: comparison and correlation between radiomics and deep learning. *European radiology*, 32(2), 747-758.
- Mann, M., Kumar, C., Zeng, W. F., & Strauss, M. T. (2021). Artificial intelligence for proteomics and biomarker discovery. *Cell systems*, 12(8), 759-770.
- Maziotis, E., Sfakianoudis, K., Giannelou, P., Grigoriadis, S., Rapani, A., Tsioulou, P., ... & Simopoulou, M. (2020). Evaluating the value of day 0 of an ICSI cycle on

- indicating laboratory outcome. *Scientific Reports*, 10(1), 19325.
- McCallum, C., Riordon, J., Wang, Y., Kong, T., You, J. B., Sanner, S., ... & Sinton, D. (2019). Deep learning-based selection of human sperm with high DNA integrity. *Communications biology*, 2(1), 250.
- Moor, J. (2006). The Dartmouth College artificial intelligence conference: The next fifty years. *AI magazine*, 27(4), 87-87.
- Ottl, S., Amiriparian, S., Gerczuk, M., & Schuller, B. W. (2022). motilitAI: A machine learning framework for automatic prediction of human sperm motility. *iscience*, 25(8).
- Paulson, R. J. (2020). Hidden in plain sight: the overstated benefits and underestimated losses of potential implantations associated with advertised PGT-A success rates. *Human Reproduction*, 35(3), 490-493.
- Pavlovic, Z. J., Jiang, V. S., & Hariton, E. (2024). Current applications of artificial intelligence in assisted reproductive technologies through the perspective of a patient's journey. *Current Opinion in Obstetrics and Gynecology*, 36(4), 211-217.
- Rajula, H. S. R., Verlato, G., Manchia, M., Antonucci, N., & Fanos, V. (2020). Comparison of conventional statistical methods with machine learning in medicine: diagnosis, drug development, and treatment. *Medicina*, 56(9), 455.
- Roberts, J. E., Spandorfer, S. D., Fasouliotis, S. J., & Rosenwaks, Z. (2003). A history of elevated basal Follicle Stimulating Hormone (FSH) elevations is predictive of in vitro fertilization (IVF) outcome. *Fertility and Sterility*, 80, 162.

- Saadat, M., Hajiyavand, A. M., & Singh Bedi, A. P. (2018). Oocyte positional recognition for automatic manipulation in ICSI. *Micromachines*, 9(9), 429.
- Schaeffer, E., Porchia, L., López-Luna, A., Hernández-Melchor, D., & López-Bayghen, E. (2018). Aneuploidy rates inversely correlate with implantation during in vitro fertilization procedures: In Favor of PGT. In *Modern medical genetics and genomics*. IntechOpen.
- Shahali, S., Murshed, M., Spencer, L., Tunc, O., Pisarevski, L., Conceicao, J., ... & Nosrati, R. (2024). Morphology classification of live unstained human sperm using ensemble deep learning. *Advanced Intelligent Systems*, 6(11), 2400141.
- Si, K., Huang, B., & Jin, L. (2023). Application of artificial intelligence in gametes and embryos selection. *Human Fertility*, 26(4), 757-777.
- Tamir, S. (2023). Artificial intelligence in human reproduction: Charting the ethical debate over AI in IVF. *AI and Ethics*, 3(3), 947-961.
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2921-2929).

KLİNİK YÖNETİMDE YAPAY ZEKA DESTEKLİ YAKLAŞIMLAR

yaz
yayınları

YAZ Yayınları
M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar / AFYONKARAHİSAR
Tel : (0 531) 880 92 99
yazyayinlari@gmail.com • www.yazyayinlari.com

