

SAĞLIK YÖNETİMİNDE GÜNCEL KONULAR II

Editörler
Ali ARSLANOĞLU
Halil ŞENGÜL



© Copyright 2026

Bu kitabın, basım, yayın ve satış hakları Akademisyen Kitabevi A.Ş.'ne aittir. Anılan kuruluşun izni alınmadan kitabın tümü ya da bölümleri mekanik, elektronik, fotokopi, manyetik kağıt ve/veya başka yöntemlerle çoğaltılamaz, basılamaz, dağıtılamaz. Tablo, şekil ve grafikler izin alınmadan, ticari amaçlı kullanılamaz. Bu kitap T.C. Kültür Bakanlığı bandrolü ile satılmaktadır.

ISBN 978-625-362-024-0	Sayfa ve Kapak Tasarımı Akademisyen Dizgi Ünitesi
Kitap Adı Sağlık Yönetiminde Güncel Konular II	Yayıncı Sertifika No 47518
Editörler Ali ARSLANOĞLU ORCID iD: 0000-0002-4454-0397 Halil ŞENGÜL ORCID iD: 0000-0001-5745-0369	Baskı ve Cilt Vadi Matbaacılık Bisac Code MED036000
Yayın Koordinatörü Yasin DİLMEN	DOI 10.37609/akya.4158

Kütüphane Kimlik Kartı

Sağlık Yönetiminde Güncel Konular II / ed. Ali Arslanoğlu, Halil Şengül.
Ankara : Akademisyen Yayınevi Kitabevi, 2026.
186 s. : şekil, tablo. ; 160x235 mm.
Kaynakça var.
ISBN 9786253620240

UYARI

Bu üründe yer alan bilgiler sadece lisanslı tıbbi çalışanlar için kaynak olarak sunulmuştur. Herhangi bir konuda profesyonel tıbbi danışmanlık veya tıbbi tam amacıyla kullanılmamalıdır. Akademisyen Kitabevi ve alıcı arasında herhangi bir şekilde doktor-hasta, terapist-hasta ve/veya başka bir sağlık sunum hizmeti ilişkisi oluşturmaz. Bu ürün profesyonel tıbbi kararların eşleniği veya yedeği değildir. Akademisyen Kitabevi ve bağlı şirketleri, yazarları, katılımcıları, partnerleri ve sponsorları ürün bilgilerine dayalı olarak yapılan bütün uygulamalardan doğan, insanlarda ve hayvanlarda yaralanma ve/veya hasarlarından sorumlu değildir.

İlaçların veya başka kimyasalların reçete edildiği durumlarda, tavsiye edilen dozunu, ilacın uygulanacak süresi, yöntemi ve kontraendikasyonlarını belirlemek için, okuyucuya üretici tarafından her ilaca dair sunulan güncel ürün bilgisini kontrol etmesi tavsiye edilmektedir. Dozun ve hasta için en uygun tedavinin belirlenmesi, tedavi eden hekimin hastaya dair bilgi ve tecrübelerine dayanarak oluşturması, hekimin kendi sorumluluğundadır.

Akademisyen Kitabevi, üçüncü bir taraf tarafından yapılan ürüne dair değişiklikler, tekrar paketlemeler ve özelleştirmelerden sorumlu değildir.

GENEL DAĞITIM

Akademisyen Kitabevi A.Ş.

Halk Sokak 5 / A Yenışehir / Ankara
Tel: 0312 431 16 33
siparis@akademisyen.com

www.akademisyen.com

ÖNSÖZ

Akademisyen Yayınevi yöneticileri, yaklaşık 38 yıllık yayın tecrübesini, kendi tüzel kişiliklerine aktararak uzun zamandan beri, ticarî faaliyetlerini sürdürmektedir. Anılan süre içinde, başta sağlık ve sosyal bilimler, kültürel ve sanatsal konular dahil 4000'i aşkın kitabı yayımlamanın gururu içindedir. Uluslararası yayınevi olmanın alt yapısını tamamlayan Akademisyen, Türkçe ve yabancı dillerde yayın yapmanın yanında, küresel bir marka yaratmanın peşindedir.

Bilimsel ve düşünsel çalışmaların kalıcı belgeleri sayılan kitaplar, bilgi kayıt ortamı olarak yüzlerce yılın tanıklarındır. Matbaanın icadıyla varoluşunu sağlam temellere oturtan kitabın geleceği, her ne kadar yeni buluşların yörüngesine taşınmış olsa da, daha uzun süre hayatımızda yer edineceği muhakkaktır.

Akademisyen Yayınevi, kendi adını taşıyan “**Bilimsel Araştırmalar Kitabı**” serisiyle Türkçe ve İngilizce olarak, uluslararası nitelik ve nicelikte, kitap yayımlama sürecini başlatmış bulunmaktadır. Her yıl Mart ve Ekim aylarında gerçekleşecek olan yayımlama süreci, tematik alt başlıklarla devam edecektir. Bu süreci destekleyen tüm hocalarımıza ve arka planda yer alan herkese teşekkür borçluyuz.

Akademisyen Yayınevi A.Ş.

İÇİNDEKİLER

Bölüm 1	Yaş Dostu Sağlık Sistemleri ve Yaş Dostu Hastaneler..... 1 <i>Ayşegül DOĞAN KAYA</i>
Bölüm 2	İklim Krizleri Çağında Sağlık Yönetimi: Liderlik, Psikolojik Dayanıklılık ve Politika Adaptasyonu..... 13 <i>Kadriye SÖNMEZ</i>
Bölüm 3	Yalın Hastane Uygulanan Hastanelerin Verimliliğinin İncelenmesi..... 31 <i>Sevil GÜNAY</i> <i>Esra Çiğdem CEZLAN</i>
Bölüm 4	Sağlıkta Görüntü İşleme ve Derin Öğrenme: Klinik Karar Destek Sistemleri için Yöntemler ve Uygulamalar 53 <i>Ömer ÇELİK</i> <i>Umutcan ALTUN</i>
Bölüm 5	Engelli Bireylere Sunulan Sağlık Hizmetleri ve Rehabilitasyonda Multidisipliner Ekip Yaklaşımı..... 75 <i>Fatih ORHAN</i> <i>Umut BEYLİK</i>
Bölüm 6	Bütüncül Sağlık Hizmetlerinde Maneviyatın Yönetimsel Rolü: Kuramsal ve Uygulamalı Bir Çerçeve..... 91 <i>Ali ALU</i>
Bölüm 7	Motivasyonun Kuramsal Çerçevesi ve Sağlık Yönetimindeki Yeri 103 <i>Fatma Nuray KUŞCU ŞAHİN</i>
Bölüm 8	Sağlık Yönetimi Araştırmalarında Makine Öğrenimi Uygulaması: Tahmine Dayalı Analitikten Öğrenen Sağlık Sistemlerine..... 127 <i>Nurettin ÖNER</i>

Sađlık Yönetiminde Güncel Konular II

Bölüm 9	Dijitalleşen Sağlık Sistemleri: Farklı Ülke Modellerinde Yapay Zeka Uygulamaları.....	151
	<i>Aysel TAMTAMIŞ KURT</i>	
Bölüm 10	Network Toksikolojisi Analizlerinde Kullanılan Biyoinformatik Araçlar.....	167
	<i>Şeyma YAŞAR</i> <i>Neşe BAŞAK TÜRKMEN</i>	

YAZARLAR

Arş. Gör. Umutcan ALTUN
Hacettepe Üniversitesi, İktisadi ve İdari
Bilimler Fakültesi, Sağlık Yönetimi
Bölümü

Dr. Öğr. Üyesi Ali ALU
Aydın Adnan Menderes Üniversitesi,
Sağlık Hizmetleri Meslek Yüksekokulu,
Tıbbi Dokümantasyon ve Sekreterlik Pr.

Prof. Dr. Umut BEYLİK
Sağlık Bilimleri Üniversitesi, Gülhane
Sağlık Bilimleri Fakültesi, Sağlık Yönetimi
Bölümü

Doç .Dr Esra Çiğdem CEZLAN
İstanbul Medipol Üniversitesi, Sağlık
Bilimleri Fakültesi, Sağlık Yönetimi
Bölümü

Öğr. Gör. Dr. Ömer ÇELİK
İğdır Üniversitesi, İğdır Meslek
Yüksekokulu, Yönetim ve Organizasyon
Bölümü

Sevil GÜNAY
Sağlık Yönetimi Uzmanı, İstanbul
Medipol Üniversitesi

Öğr. Gör. Dr. Ayşegül DOĞAN KAYA
Zonguldak Bülent Ecevit Üniversitesi,
Ahmet Erdoğlan Sağlık Hizmetleri Meslek

Yüksekokulu, Dişçilik Hizmetleri Bölümü

Öğr. Gör. Dr. Aysel TAMTAMIŞ KURT
Ataşehir Adıgüzel Meslek Yüksekokulu,
Tıbbi Dokümantasyon ve Sekreterlik Pr.

Dr. Öğr. Üyesi Fatih ORHAN
Sağlık Bilimleri Üniversitesi, Gülhane
Sağlık Meslek Yüksekokulu, Yönetim ve
Organizasyon Bölümü

Dr. Öğr. Üyesi Nurettin ÖNER
Ankara Üniversitesi, Sağlık Bilimleri
Fakültesi, Sağlık Yönetimi Bölümü

Dr. Öğr. Üyesi Kadriye SÖNMEZ
İstanbul Topkapı Üniversitesi, Plato
Meslek Yüksekokulu, Tıbbi Hizmetler ve
Teknikler Bölümü

**Dr. Öğr. Üyesi Fatma Nuray KUŞCU
ŞAHİN**
Hatay Mustafa Kemal Üniversitesi, Hatay
Sağlık Hizmetleri Meslek Yüksekokulu

Doç. Dr. Neşe BAŞAK TÜRKMEN
İnönü Üniversitesi, Eczacılık Fakültesi,
Farmasötik Toksikoloji AD.

Doç. Dr. Şeyma YAŞAR
İnönü Üniversitesi, Tıp Fakültesi
Biyostatistik ve Tıp Bilişimi AD.

BÖLÜM 1

YAŞ DOSTU SAĞLIK SİSTEMLERİ VE YAŞ DOSTU HASTANELER

Ayşegül DOĞAN KAYA¹

GİRİŞ

Günümüzde bireyler; beslenme koşullarının iyileşmesi, hijyen standartlarının yükselmesi, sağlık hizmetlerine erişimin ve etkinliğinin artması ile eğitim ve ekonomik düzeydeki gelişmelerin etkisiyle daha uzun bir yaşam süresine ulaşmaktadır. Bununla birlikte, nüfusun yaşlanmasına bağlı olarak ortaya çıkan ekonomik ve toplumsal güçlükler, küresel ölçekte önemli bir sorun alanı olarak öne çıkmaktadır. Yaşlı nüfusta çoklu hastalık yükünün artması, sağlık harcamalarının yükselmesine yol açarken, demografik yaşlanma süreci sağlık hizmetlerine olan talebi de belirgin biçimde artırmaktadır (1). Dünya genelinde yaşlı nüfus oranındaki sürekli artış, sağlık hizmetlerinin sunumunda yenilikçi ve uyumlu yaklaşımların geliştirilmesini gerekli kılmaktadır. Yaşlanma sürecine özgü çok boyutlu dinamiklerin sağlık üzerindeki olumlu ve olumsuz etkileri, yaşlılığa ilişkin konuların bütüncül bir perspektifle ele alınmasını zorunlu hale getirmektedir (2). Bu bağlamda, sağlık kuruluşlarında yaşlı dostu uygulamaların yaygınlaştırılması ve kurumsal bir kültür haline dönüştürülmesi amacıyla, yüksek nitelikli, maliyet-etkin ve kanıta dayalı geriatrik bakım modelleri ile bu modelleri destekleyecek kaynakların geliştirilmesi, milyonlarca birey ve toplum sağlığı açısından kritik bir gereksinimdir (3).

Bu çalışma kapsamında, öncelikle yaşlanma olgusu ve yaşlanmanın sağlık hizmetlerine olan talep üzerindeki etkileri ele alınacak; ardından yaş dostu sağlık sistemleri ile yaş dostu hastane kavramı açıklanarak, Türkiye'deki güncel uygulama-

¹ Öğr. Gör. Dr., Zonguldak Bülent Ecevit Üniversitesi, Ahmet Erdoğın Sağlık Hizmetleri Meslek Yüksekokulu, Dişçilik Hizmetleri Bölümü, dt_aysegul_dogan@hotmail.com, ORCID iD: 0000-0002-5814-6710

üstlenmeyi hedeflemektedir (10).

SONUÇ

Yaş dostu bir sağlık sistemi, geriatri alanında eğitim almış uzmanlar ve yaşlı bakımına ilişkin yeterliliğe sahip insan kaynağı aracılığıyla, yaşlı bireylerin özgün gereksinimlerine uyarlanmış ve kanıta dayalı bakım hizmetleri sunmaktadır. Yönetim anlayışı, yaş ayrımcılığıyla mücadeleyi önceleyen bir yaklaşımı benimseyerek, yaşlı bireylerin, ailelerinin ve bakıcılarının bakım ve tedavi süreçlerinde karar alma mekanizmalarına aktif biçimde katılımını destekleyen bir ortam oluşturmayı hedeflemektedir. Bu sistem, yaşlı yetişkinlerin bakımında tıbbi unsurların yanı sıra psikososyal boyutlara da odaklanmakta; sağlığın korunması ve sağlıklı yaşlanmanın desteklenmesi doğrultusunda önleyici bir yaklaşım benimsemekte ve potansiyel sağlık gereksinimlerini proaktif bir şekilde ele almaktadır. Ayrıca, yaşam sonu bakımına gereksinim duyan ciddi hastalığı bulunan bireyler için bakım kalitesinin artırılmasını amaçlamaktadır. Yaşlı nüfusun giderek artması karşısında, sağlık sistemlerinin rutin hizmet sunumunun ötesine geçerek bu grubun çok boyutlu sağlık gereksinimlerine yanıt verecek biçimde yapılandırılması, mevcut kaynakların yaşlı bireylerin ihtiyaçları doğrultusunda tahsis edilmesi ve yaşam kalitesini artırmaya yönelik bileşenlerin yeniden düzenlenmesi gerekmektedir.

KAYNAKLAR

1. Aydın GZ, Demirci HF. Yaşlıların sağlık hizmeti memnuniyetini artırmaya ilişkin bir uygulama: Yaşlı dostu hastane. *Akşehir Meslek Yüksekokulu Sosyal Bilimler Dergisi*, 2023;15: 155-167.
2. Eren Bana P. Yaşlılık döneminde yaşam kalitesi sosyal güvence ve sağlık hizmetleri. *Dynamics in Social Sciences and Humanities*, 2025; 6(1): 34-43. Doi:10.62425/dssh.1543088
3. Fulmer T., Mate, K.S., Berman, A. The age-friendly health system imperative. *J Am Geriatr Soc*. 2018; 66(1): 22-4.
4. Çunkuş N., Taşdemir Yiğitoğlu, G., & Akbaş, E. Yaşlılık ve toplumsal dışlanma. *Geriatik Bilimler Dergisi*, 2019; 2(2), 58-67.
5. Duvan E.K. ve Kantar Davran M. Yaşlılık olgusu ve kırsal alanda yaşlılık. Ankara: İksad Yayınevi; 2023
6. Büken N.Ö. & Büken E. Yaşlanma olgusu ve tıp etiği. *Geriatri*, 2003; 6 (2), 75-79.
7. Baş E. Elderly health services in primary health care institutions and nursing approach. *Experimental and Applied Medical Science*, 2025; 6(3): 220-223.
8. Kocakoç N. Yaşlılık Sağlık harcamalarının geografik dağılımı: farklı bölgelerde yaşlı sağlık harcamalarında gözlemlenen değişiklikler. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 2024; 27(1):152-167.
9. Fan B., Wang M., Chen M. et al. Age-friendly hospitals: a concept analysis. *BMC Geriatr*, 2025; 25:726.
10. T.C. Sağlık Bakanlığı 2023. (19/01/2026 tarihinde <https://www.saglik.gov.tr/TR-99548/80-yas-ve-uzeri-hastalar-yasama-emanet-edilecek.html> adresinden ulaşılmıştır).
11. Aydemir İ., Yaşar M. E. Demografik değişim kuramının sağlık, hastalık ve sağlık harcamaları üzerindeki etkisine ilişkin literatür değerlendirmesi. *Sıirt Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 2020; 8(15):102-116.

12. Lee S., Skains R. M., Magidson P. D., Qadoura N., Liu S. W., Southerland L. T. Enhancing healthcare access for an older population: The age-friendly emergency department. *JACEP Open*, 2024; 5(3): 13182.
13. Erkan Bal Ç., Kabcuk E., Kutluay Tutar F. Gümüş ekonomi Türkiye için bir avantaj mı, tehdit mi? *Journal of Economics and Research*, 2025; 6(2):1-20.
14. Zisberg A., Rayan-Gharra N., Danial-Saad A., Rogozinski A., Fraiman P.S., Segel-Karpas D. Age-friendly healthcare: an evolutionary concept analysis. *J Clin Nurs.*, 2023; 33(12): 4635-4650.
15. Mate K. S., Berman A., Laderman M., Kabcenell A., Fulmer T. Creating age-friendly health systems - a vision for better care of older adults. *Healthcare*, 2018; 6 (1): 4–6.
16. Sanford A. M., Elliott, S. J. Developing an aging-friendly healthcare system. *Missouri Medicine*, 2025; 122(2): 102.
17. Cacchione P.Z. Age-friendly health systems: the 4Ms framework. *Clinical Nursing Research.*, 2020; 29(3):139-140.
18. Church K., Munro S., Shaughnessy M., Clancy C. Age-friendly health systems: improving care for older adults in the Veterans Health Administration. *Health Serv Res.*, 2023; 1(1): 5-8.
19. Özmen S., Koyuncu S. Dost hastane kavramı ve türleri üzerine sistematik bir derleme. *Hacettepe Sağlık İdaresi Dergisi*, 2023; 26(3): 723-744.
20. Scheerman K., Klaverweide J. R., Meskers C. G., Maier A. B. Toward senior-friendly hospitals: an overview of programs, their elements and effectiveness in improving care. *Gerontology*, 2025; 71(1):1-12.
21. Gemlik, N., Aydın, A., & Arslanoğlu, A. Yaşlı Dostu Hastaneye Yaşlı Dostu Gelişim Komitesinin Bakışı: Nitel Bir Araştırma. *Sağlık Ve Sosyal Refah Araştırmaları Dergisi*, 2022; 4(2): 175-185.
22. TÜİK İstatistiklerle yaşlılar 2022 (15/01/2026 tarihinde: https://www.tuik.gov.tr/media/announcements/istatistiklerle_yaslilar_tr.pdf adresinden ulaşılmıştır).
23. TÜİK İstatistiklerle yaşlılar 2025 (15/01/2026 tarihinde: <https://data.tuik.gov.tr/Bulten/Index?p=Istatistiklerle-Yaslilar-2024-54079> adresinden ulaşılmıştır).
24. TÜSKA 2019 (15/01/2026 tarihinde: <https://tuska.tuseb.gov.tr/haberler/yasli-dostu-hastane-calistayina-katilim-saglandi-20221107> adresinden ulaşılmıştır).
25. Burdur Valiliği 2022 (05/02/2026 tarihinde: <https://www.burdur.gov.tr/burdurda-saglikta-bir-ilk-tum-hastanelerde-yasli-dostu-hastane-konsepti-ile-saglik-hizmeti> adresinden ulaşılmıştır).
26. Isparta İl Sağlık Müdürlüğü 2022 (05/02/2026 tarihinde: <https://ispartaism.saglik.gov.tr/TR-235145/yasli-dostu-hastane.html> adresinden ulaşılmıştır).

BÖLÜM 2

İKLİM KRİZLERİ ÇAĞINDA SAĞLIK YÖNETİMİ: LİDERLİK, PSİKOLOJİK DAYANIKLILIK VE POLİTİKA ADAPTASYONU

Kadriye SÖNMEZ¹

1. GİRİŞ

21. yüzyıl, sağlık sistemleri bakımından, sadece teknolojik olarak değişim ve gelişimler olmamakla birlikte, karmaşık yapıda ve hepsinin arasında da koordinasyonlu krizlerin yaşandığı bir çağ şeklinde görülmektedir. Yaşanılan çağda toplumun karşılaşmış olduğu pandemi, iklim değişikliği, kitlesel göçler, biyolojik bakımdan tehlikeler, hızlı ekonomik değişimler ve coğrafi dengesizlikler beraberinde sağlık alanını da direkt etkilemektedir. Böyle çoklu bir kriz ortamı, sunulan sağlık hizmetlerinin sadece klinik tarafındaki becerilerini değil, yönetim alanında uyumluluk, liderlik niteliği ve politika uyum kabiliyetini de beraberinde yoklamaktadır (Kickbusch et al., 2021).

Bilhassa, COVID-19 pandemisi, sağlık alanında sistemlerin kriz durumlarına karşı hazır olma kapasitesini, yönetsel anlamda karar alma durumunu ve liderlik becerisinin önemi küresel açıdan görülmüştür. Aynı zamanda pandemi, yalnız bir kriz durumu yaratmanın ötesinde, daha kapsamlı bir kırılma zeminini ortaya çıkarmıştır. Bahsedilen kırılma konularının en belirgin olanı ise iklim değişikliğinin sağlık sistemleri üzerinde artış gösteren ve kalıcı olan etkileridir (Romanello et al., 2022).

İklim krizleri, çağımızda ileriye dönük tahmin edilen bir risk olarak düşünülmemekte, sağlık sistemlerinin gündelik çalışmasına direkt etki ederek yapısal bir gerçeklik şekline dönüşmüştür. Görülen yüksek hava dalgaları, sel ve yangınlar, hava kirliliği, kirli su nedenli hastalıklar ve vektör nedenli enfeksiyonlarda görülen yükseliş, sağlık hizmetlerine yönelik talebi değiştirmekte ve kaynak yönetimi-

¹ Dr. Öğr. Üyesi, İstanbul Topkapı Üniversitesi, Plato Meslek Yüksekokulu, Tıbbi Hizmetler ve Teknikler Bölümü, kadrish_0134@hotmail.com, ORCID iD: 0009-0000-5981-8577

Bu çerçeve, iklim krizleri çağında sağlık yönetiminin insan boyutunu politika boyutuyla bütünleştiren disiplinlerarası bir yaklaşım önermektedir.

KAYNAKLAR

- Boin, A., 't Hart, P., Stern, E., & Sundelius, B. (2017). *The politics of crisis management: Public leadership under pressure* (2nd ed.). Cambridge University Press. <https://doi.org/10.1017/9781316339756>
- Ebi, K. L., Capon, A., Berry, P., Broderick, C., de Dear, R., Havenith, G., Honda, Y., Kovats, R. S., Ma, W., Malik, A., & Sari Kovats, R. (2021). Hot weather and heat extremes: Health risks. *The Lancet*, 398(10301), 698–708. [https://doi.org/10.1016/S0140-6736\(21\)01208-3](https://doi.org/10.1016/S0140-6736(21)01208-3)
- Kickbusch, I., Leung, G. M., Bhutta, Z. A., Matsoso, M. P., Ihekweazu, C., & Abbasi, K. (2021). Covid-19: How a virus is turning the world upside down. *BMJ*, 369, m1336. <https://doi.org/10.1136/bmj.m1336>
- Romanello, M., McGushin, A., Di Napoli, C., et al. (2022). The 2022 report of the Lancet Countdown on health and climate change. *The Lancet*, 400(10363), 1619–1654. [https://doi.org/10.1016/S0140-6736\(22\)01540-9](https://doi.org/10.1016/S0140-6736(22)01540-9)
- Southwick, S. M., Bonanno, G. A., Masten, A. S., Panter-Brick, C., & Yehuda, R. (2014). Resilience definitions, theory, and challenges. *European Journal of Psychotraumatology*, 5(1), 25338. <https://doi.org/10.3402/ejpt.v5.25338>
- Watts, N., Amann, M., Arnell, N., et al. (2018). The 2018 report of the Lancet Countdown on health and climate change. *The Lancet*, 392(10163), 2479–2514. [https://doi.org/10.1016/S0140-6736\(18\)32594-7](https://doi.org/10.1016/S0140-6736(18)32594-7)
- World Health Organization. (2021). COP26 special report on climate change and health. World Health Organization.
- Berry, H. L., Waite, T. D., Dear, K. B. G., Capon, A. G., & Murray, V. (2018). The case for systems thinking about climate change and mental health. *Nature Climate Change*, 8(4), 282–290. <https://doi.org/10.1038/s41558-018-0102-4>
- Boin, A., 't Hart, P., Stern, E., & Sundelius, B. (2017). *The politics of crisis management: Public leadership under pressure* (2nd ed.). Cambridge University Press. <https://doi.org/10.1017/9781316339756>
- Ebi, K. L., Capon, A., Berry, P., et al. (2021). Hot weather and heat extremes: Health risks. *The Lancet*, 398(10301), 698–708. [https://doi.org/10.1016/S0140-6736\(21\)01208-3](https://doi.org/10.1016/S0140-6736(21)01208-3)
- Kickbusch, I., Leung, G. M., Bhutta, Z. A., Matsoso, M. P., Ihekweazu, C., & Abbasi, K. (2021). Covid-19: How a virus is turning the world upside down. *BMJ*, 369, m1336. <https://doi.org/10.1136/bmj.m1336>
- Romanello, M., McGushin, A., Di Napoli, C., et al. (2022). The 2022 report of the Lancet Countdown on health and climate change. *The Lancet*, 400(10363), 1619–1654. [https://doi.org/10.1016/S0140-6736\(22\)01540-9](https://doi.org/10.1016/S0140-6736(22)01540-9)
- Watts, N., Amann, M., Arnell, N., et al. (2018). The 2018 report of the Lancet Countdown on health and climate change. *The Lancet*, 392(10163), 2479–2514. [https://doi.org/10.1016/S0140-6736\(18\)32594-7](https://doi.org/10.1016/S0140-6736(18)32594-7)
- World Health Organization. (2021). COP26 special report on climate change and health. World Health Organization.
- Barasa, E., Cloete, K., & Gilson, L. (2018). From bouncing back, to nurturing emergence: Reframing the concept of resilience in health systems strengthening. *Health Policy and Planning*, 33(5), 491–503. <https://doi.org/10.1093/heapol/czy009>
- Boin, A., 't Hart, P., Stern, E., & Sundelius, B. (2017). *The politics of crisis management: Public leadership under pressure* (2nd ed.). Cambridge University Press. <https://doi.org/10.1017/9781316339756>
- Ebi, K. L., Capon, A., Berry, P., et al. (2021). Hot weather and heat extremes: Health risks. *The Lan-*

- cet, 398(10301), 698–708. [https://doi.org/10.1016/S0140-6736\(21\)01208-3](https://doi.org/10.1016/S0140-6736(21)01208-3)
- Folke, C., Carpenter, S. R., Walker, B., Scheffer, M., Chapin, T., & Rockström, J. (2010). Resilience thinking: Integrating resilience, adaptability and transformability. *Ecology and Society*, 15(4), 20. <https://doi.org/10.5751/ES-03610-150420>
- Friedman, C. P., Rubin, J. C., & Sullivan, K. J. (2017). Toward an information infrastructure for global health improvement. *Yearbook of Medical Informatics*, 26(1), 16–23. <https://doi.org/10.15265/IY-2017-005>
- Romanello, M., McGushin, A., Di Napoli, C., et al. (2022). The 2022 report of the Lancet Countdown on health and climate change. *The Lancet*, 400(10363), 1619–1654. [https://doi.org/10.1016/S0140-6736\(22\)01540-9](https://doi.org/10.1016/S0140-6736(22)01540-9)
- World Health Organization. (2021). COP26 special report on climate change and health. World Health Organization.
- Bass, B. M., & Riggio, R. E. (2006). *Transformational leadership* (2nd ed.). Psychology Press.
- Boin, A., 't Hart, P., Stern, E., & Sundelius, B. (2017). *The politics of crisis management: Public leadership under pressure* (2nd ed.). Cambridge University Press. <https://doi.org/10.1017/9781316339756>
- Duchek, S. (2020). Organizational resilience: A capability-based conceptualization. *Business Research*, 13(1), 215–246. <https://doi.org/10.1007/s40685-019-0085-7>
- Heifetz, R., Grashow, A., & Linsky, M. (2009). *The practice of adaptive leadership*. Harvard Business Press.
- Southwick, S. M., Bonanno, G. A., Masten, A. S., Panter-Brick, C., & Yehuda, R. (2014). Resilience definitions, theory, and challenges. *European Journal of Psychotraumatology*, 5(1), 25338. <https://doi.org/10.3402/ejpt.v5.25338>
- Duchek, S. (2020). Organizational resilience: A capability-based conceptualization. *Business Research*, 13(1), 215–246. <https://doi.org/10.1007/s40685-019-0085-7>
- Harms, P. D., Credé, M., Tynan, M., Leon, M., & Jeung, W. (2017). Leadership and stress: A meta-analytic review. *The Leadership Quarterly*, 28(1), 178–194. <https://doi.org/10.1016/j.leaqua.2016.10.006>
- Masten, A. S. (2014). Global perspectives on resilience in children and youth. *Child Development*, 85(1), 6–20. <https://doi.org/10.1111/cdev.12205>
- Maslach, C., & Leiter, M. P. (2016). Understanding the burnout experience. *World Psychiatry*, 15(2), 103–111. <https://doi.org/10.1002/wps.20311>
- Robertson, I. T., Cooper, C. L., Sarkar, M., & Curran, T. (2015). Resilience training in the workplace. *Journal of Occupational and Organizational Psychology*, 88(3), 533–562. <https://doi.org/10.1111/joop.12120>
- Southwick, S. M., Bonanno, G. A., Masten, A. S., Panter-Brick, C., & Yehuda, R. (2014). Resilience definitions, theory, and challenges. *European Journal of Psychotraumatology*, 5(1), 25338. <https://doi.org/10.3402/ejpt.v5.25338>
- Ebi, K. L., Capon, A., Berry, P., et al. (2021). Hot weather and heat extremes: Health risks. *The Lancet*, 398(10301), 698–708. [https://doi.org/10.1016/S0140-6736\(21\)01208-3](https://doi.org/10.1016/S0140-6736(21)01208-3)
- Romanello, M., McGushin, A., Di Napoli, C., et al. (2022). The 2022 report of the Lancet Countdown on health and climate change. *The Lancet*, 400(10363), 1619–1654. [https://doi.org/10.1016/S0140-6736\(22\)01540-9](https://doi.org/10.1016/S0140-6736(22)01540-9)
- Watts, N., Amann, M., Arnell, N., et al. (2018). The 2018 report of the Lancet Countdown on health and climate change. *The Lancet*, 392(10163), 2479–2514. [https://doi.org/10.1016/S0140-6736\(18\)32594-7](https://doi.org/10.1016/S0140-6736(18)32594-7)
- World Health Organization. (2021). COP26 special report on climate change and health. World Health Organization.
- Barasa, E., Cloete, K., & Gilson, L. (2018). From bouncing back, to nurturing emergence: Reframing the concept of resilience in health systems strengthening. *Health Policy and Planning*, 33(5), 491–503. <https://doi.org/10.1093/heapol/czy009>
- Bass, B. M., & Riggio, R. E. (2006). *Transformational leadership* (2nd ed.). Psychology Press.

- Duchek, S. (2020). Organizational resilience: A capability-based conceptualization. *Business Research*, 13(1), 215–246. <https://doi.org/10.1007/s40685-019-0085-7>
- Friedman, C. P., Rubin, J. C., & Sullivan, K. J. (2017). Toward an information infrastructure for global health improvement. *Yearbook of Medical Informatics*, 26(1), 16–23. <https://doi.org/10.15265/IY-2017-005>
- Heifetz, R., Grashow, A., & Linsky, M. (2009). *The practice of adaptive leadership*. Harvard Business Press.
- Romanello, M., McGushin, A., Di Napoli, C., et al. (2022). The 2022 report of the Lancet Countdown on health and climate change. *The Lancet*, 400(10363), 1619–1654. [https://doi.org/10.1016/S0140-6736\(22\)01540-9](https://doi.org/10.1016/S0140-6736(22)01540-9)
- Southwick, S. M., Bonanno, G. A., Masten, A. S., Panter-Brick, C., & Yehuda, R. (2014). Resilience definitions, theory, and challenges. *European Journal of Psychotraumatology*, 5(1), 25338. <https://doi.org/10.3402/ejpt.v5.25338>
- World Health Organization. (2021). *COP26 special report on climate change and health*. World Health Organization.

BÖLÜM 3

YALIN HASTANE UYGULANAN HASTANELERİN VERİMLİLİĞİNİN İNCELENMESİ

Sevil GÜNAY ¹
Esra Çiğdem CEZLAN ²

SAĞLIK SİSTEMİ VE YALIN YÖNETİM KAVRAMI

Artan sağlık hizmeti talebine karşın finansal, beşerî ve fiziksel kaynakların sınırlı olması; sağlık kurumlarını daha etkin, verimli ve sürdürülebilir yönetim modelleri arayışına yöneltmiştir. Bu bağlamda hastaneler, sağlık sistemlerinin en karmaşık ve maliyet yoğun bileşenleri olarak, verimlilik tartışmalarının merkezinde yer almaktadır.

Geleneksel yönetim yaklaşımlarının karmaşık yapıya sahip olan hastaneleri yönetmede yetersiz kaldığı; uzun bekleme süreleri, gereksiz tekrarlar, iş yükü dengesizlikleri, kaynak israfları ve kalite sorunlarının yaygın biçimde ortaya çıktığı bildirilmektedir (1). Bu durum, sağlık hizmetlerinde yalnızca klinik sonuçlara değil, aynı zamanda süreçlerin nasıl tasarlandığına ve yönetildiğine odaklanan yaklaşımların önemini artırmıştır.

Yalın düşüncenin merkezine hasta değeri ve israfın ortadan kaldırılması yerleştirilmiştir (2). Yalın yönetim uygulamalarının, israfların (muda) ortadan kaldırılması, hasta akışının düzenlenmesi, çalışan katılımının artırılması ve süreçlerin standartlaştırılması yoluyla hastane verimliliğini doğrudan artırdığı gösterilmiştir (3,4). Bu bağlamda yalın uygulamalar sayesinde; bekleme süreleri kısalmış, gereksiz işlemler azalmış, personel performansı yükselmiş, kaynak kullanımı optimize edilmiştir (5).

¹ Sağlık Yönetimi Uzmanı, İstanbul Medipol Üniversitesi, sewiltuzak@gmail.com, ORCID iD: 0009-0001-9781-2421

² Doç .Dr, İstanbul Medipol Üniversitesi, Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölümü, eccezlan@medipol.edu.tr, ORCID iD: 0000-0002-9238-4907

PKYD vb.) daha sürdürülebilir sonuçlar üretir. Hastanelerde yalın uygulamaların öncelikle hasta akışının yoğun olduğu yüksek hacim–yüksek bekleme alanlarından (acil servisler, poliklinikler, ameliyathaneler, taburculuk süreçleri) pilot çalışmalarla başlatılması önerilmektedir. DAH ile mevcut durum analizi; ardından hızlı kazanımlar için 5S ve standart iş uygulanmalıdır. Pilot uygulamalar sayesinde süreç haritaları çıkarılmalı, değer katan ve değer katmayan faaliyetler net biçimde tanımlanmalı ve israflar sistematik olarak ortadan kaldırılmalıdır. Süre, hata, maliyet, kapasite, memnuniyet; düzenli olarak raporlanmalıdır. Elde edilen kazanımlar, daha sonra kurum geneline yaygınlaştırılmalıdır

KAYNAKLAR

1. Institute of Medicine. (2001). *Crossing the quality chasm: A new health system for the 21st century*. National Academies Press. <https://pubmed.ncbi.nlm.nih.gov/25057539/>
2. Joosten, T., Bongers, I., & Janssen, R. (2009). Application of lean thinking to health care: Issues and observations. *International Journal for Quality in Health Care*, 21(5), 341.
3. Graban, M. (2018). *Lean hospitals: Improving quality, patient safety, and employee engagement* (3rd bs).
4. Radnor, Z. J., Holweg, M., & Waring, J. (2012). Lean in healthcare: The unfilled promise? *Social Science & Medicine*, 74(3), 364-371.
5. Zepeda-Lugo, C., Tlapa, D., & Baez-Lopez, Y. (2020). Assessing the Impact of Lean Healthcare on Inpatient Care: A Systematic Review. *International Journal of Environmental Research and Public Health*, 17(15), 5609.
6. *Quality in business: Concept and definition*. (t.y.). Geliş tarihi 07 Eylül 2025, gönderen <https://collectionperformance.com/quality-in-business-concept-and-definition/>
7. Nanda, V. (t.y.). *Quality Management System Handbook for Product Development Companies*. Geliş tarihi 31 Ağustos 2025, gönderen https://books.google.com.tr/books?id=guizsuAAyR-4C&pg=PA1&redir_esc=y#v=onepage&q&f=false
8. Ciampa, D. (1991). *Total quality: A users' guide for implementation*.
9. *Understanding Quality Measurement*. (t.y.). Agency for Healthcare Research and Quality. Geliş tarihi 31 Ağustos 2025, gönderen <https://www.ahrq.gov/patient-safety/quality-resources/tools/chttoolbx/understand/index.html>
10. Chassin, M. R., Galvin, R. W., & Donaldson, M. S. (1998). The Urgent Need to Improve Health Care Quality. *JAMA*, 280(11), 1000-1005.
11. Ohno, T. (t.y.). *Toyota Production System: Beyond Large-Scale Production*. Geliş tarihi 10 Eylül 2025, gönderen https://books.google.com.tr/books?id=7_-67SshOy8C&printsec=frontcover&redir_esc=y#v=onepage&q&f=false
12. *The Fundamentals and Advantages of the Lean Methodology*. (t.y.). KaiNexus Blog. Geliş tarihi 11 Eylül 2025, gönderen <https://blog.kainexus.com/the-fundamentals-of-the-lean-methodology>
13. Abu Bakar, K., Mohd. Sam, M. F., & Qureshi, M. I. (2022). Lean manufacturing design of a two-sided assembly line balancing problem work cell. *Lecture Notes in Mechanical Engineering*, 25, 249-259.
14. Womack, J. P., & Jones, D. T. (1997). Lean thinking—Banish waste and create wealth in your corporation. *Journal of the Operational Research Society*, 48(11), 1148.
15. Imai, M. (2007). *Gemba Kaizen: A Commonsense, Low-Cost Approach to Management*.
16. Liker, J. K. (t.y.). *The 14 principles of the Toyota way: An executive summary of the culture behind TPS*. Geliş tarihi <https://www.researchgate.net/publication/290007864>
17. *The Impact of Lean Manufacturing Concepts on Industrial Processes' Efficiency and Waste Re-*

- duction. (t.y.). ResearchGate. Geliş tarihi 14 Eylül 2025, gönderen https://www.researchgate.net/publication/381250819_THE_IMPACT_OF_LEAN_MANUFACTURING_CONCEPTS_ON_INDUSTRIAL_PROCESSES%E2%80%99EFFICIENCY_AND_WASTE_REDUCTION
18. Rother, M., & Shook, J. (2018). *Learning to see: Value-stream mapping to create value and eliminate muda*. https://www.researchgate.net/publication/244433983_Learning_to_See_Value_Stream_Mapping_to_Create_Value_and_Eliminate_Muda
 19. Sobek, D. K., & Smalley, A. (2008). *Understanding A3 thinking: A critical component of Toyota's PDCA management system*.
 20. Kaplan, G. S., Patterson, S. H., Ching, J. M., & Blackmore, C. (2014). Why Lean doesn't work for everyone. *BMJ Quality & Safety*, 23(12), 970-973.
 21. van Rossum, L., Aij, K. H., Simons, F. E., van der Eng, N., & ten Have, W. D. (2016). Lean healthcare from a change management perspective. *Journal of Health Organization and Management*, 30(3), 475-493.
 22. Kinsman, L., Rotter, T., Stevenson, K., Bath, B., Goodridge, D., & Harrison, L. (2014). The largest Lean transformation in the world: The implementation and evaluation of lean in Saskatchewan healthcare. *Healthcare Quarterly*, 17(2), 29-32.
 23. Dellifraire, J. L., Langabeer, J. R., & Nembhard, I. M. (2010). Assessing the evidence of Six Sigma and Lean in the health care industry. *Quality Management in Health Care*, 19(3), 211-225.
 24. Üyess, Ö., Kiliçarslan, M., & Hastane, Y. (2018). *Sağlıkta İsrar*. <https://iksadyayinevi.com/wp-content/uploads/2020/02/SA%C4%9ELIKTA-%C4%B0SRAF-YALIN-HASTANE-.pdf>
 25. Toussaint, J. S., & Berry, L. L. (2013). The promise of lean in health care. *Mayo Clinic Proceedings*, 88(1), 74-82.
 26. D'Andreamatteo, A., Ianni, L., Lega, F., & Sargiacomo, M. (2015). Lean in healthcare: A comprehensive review. *Health Policy*, 119(9), 1197-1209.
 27. Timurtas, M. (2020). Hastanelerde Yalın Altı Sigma Uygulamalarının Verimlilik Ve Performansa Etkisi; Bir Sistematik Derleme. *Sağlıkta Kalite ve Akreditasyon Dergisi*, 3(2), 1-9.
 28. Doğan, N. Ö., & Yağlı, B. Ş. (2019). Sağlık sektöründe yalın düşünce: Bir literatür derlemesi. *Hacettepe Sağlık İdaresi Dergisi*, 22(2), 467-490.
 29. de Barros, L. B., Bassi, L. de C., Caldas, L. P., Sarantopoulos, A., Zeferino, E. B. B., & Minatogawa, V. (2021). Lean Healthcare Tools for Processes Evaluation: An Integrative Review. *International Journal of Environmental Research and Public Health*, 18(14).
 30. Acar, S. (2023). Yalın Yönetimin Sağlık Sektörü Uygulamalarına İlişkin Örnekler ve Literatür İncelemesi. *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (26), 241-263.
 31. Talero-Sarmiento, L. H., Escobar-Rodríguez, L. Y., Gomez-Avila, F. L., & Parra-Sanchez, D. T. (2024). A literature review on Lean healthcare: Implementation strategies, challenges, and future research directions. *Cogent Engineering*, 11(1).
 32. Wang, J., Lv, H., Chen, M., Liu, C., Ren, W., Jiang, H., & Zhang, L. (2025). A Systematic Review of Lean Implementation in Hospitals: Impact on Efficiency, Quality, Cost, and Satisfaction. *International Journal of Health Policy and Management*, 14, 8974.

BÖLÜM 4

SAĞLIKTA GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME: KLİNİK KARAR DESTEK SİSTEMLERİ İÇİN YÖNTEMLER VE UYGULAMALAR

Ömer ÇELİK¹
Umutcan ALTUN²

1. GİRİŞ

Sağlık hizmetlerinde giderek ağırlaşan iş yükü ve hataların klinik açıdan telafi edilemez sonuçları, bu alanda yenilikçi teknik yöntemlere ve ileri teknolojik çözümlere duyulan ihtiyacı her geçen gün daha belirgin biçimde artırmaktadır. Bu bağlamda tıbbi görüntüleme, modern sağlık hizmetlerinin vazgeçilmez bir bileşeni haline gelmiş ve hastalıkların erken tanısından tedavi planlanmasına kadar uzanan geniş bir yelpazede klinisyenlere kritik bilgi sağlamaktadır (1). Geleneksel olarak bu süreç, deneyimli uzmanların görsel yorumlamalarına dayanmakta; ancak artan hasta sayısı, karmaşıklaşan görüntü modaliteleri ve radyolog açığı gibi yapısal sorunlar, manuel değerlendirme süreçlerinin sınırlarını giderek daha belirgin biçimde ortaya koymaktadır (2). Öznellik, yorumlayıcılar arası tutarsızlık ve yorgunluk (3) kaynaklı hata riski, bu sınırlılıkların başında gelmekte ve klinisyenleri daha güvenilir, hızlı ve ölçeklenebilir tanısal destek arayışına yöneltmektedir (4,5).

Bu ihtiyaca yanıt olarak gelişen derin öğrenme yöntemleri, tıbbi görüntü analizinde kısa sürede çığır açan bir dönüşümü beraberinde getirmiştir. Özellikle evrişimli sinir ağları (CNN) ve bunların ResNet, U-Net ve EfficientNet (6) gibi gelişmiş türevleri; tümör tespiti, inme tanısı, akciğer hastalıkları ve retinopati gibi kritik klinik senaryolarda uzman hekim düzeyiyle kıyaslanabilir, hatta kimi zaman onu aşan doğruluk oranlarına ulaşmaktadır (7). Bu modeller, ham görüntü

¹ Öğr. Gör. Dr., Iğdır Üniversitesi, Iğdır Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, omer.celik@igdir.edu.tr, ORCID iD: 0000-0001-9342-5443

² Arş. Gör., Hacettepe Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Sağlık Yönetimi Bölümü, umutcanaltun@hacettepe.edu.tr, ORCID iD: 0000-0003-2452-1137

liği perspektifinden de değerlendirilmesi gerektiğini açıkça ortaya koymaktadır. Türkiye özelinde, SGK kaynaklarının sürdürülebilirliğine yönelik artan baskı göz önünde bulundurulduğunda, istem yönetimi işleviyle donatılmış KKDS çözümlerinin sağlık finansman politikalarına entegre edilmesi stratejik bir öncelik olarak ele alınmalıdır.

Önümüzdeki süreçte alanın ilerlemesi, yalnızca daha derin ve daha doğru modeller geliştirmekle sınırlı kalmayacak, çok modlu veri entegrasyonu, federe öğrenme gibi gizlilik koruyucu mimariler ve gerçek dünya klinik ihtiyaçlarına yanıt veren uyarlanabilir sistemlerin geliştirilmesi de belirleyici bir önem kazanacaktır. Klinik karar destek sistemlerinin sağlık ekosistemiyle gerçek anlamda bütünleşebilmesi için teknik mükemmeliyetin yanı sıra klinisyen-algoritma iş birliği, düzenleyici çerçeveler ve etik sorumluluk ilkelerine dayanan disiplinlerarası bir yaklaşım kaçınılmazdır. Nihayetinde bu teknolojilerin hedefi, hekimin klinik yarısının yerini almak değil, onu daha hızlı, daha isabetli ve daha güvenilir kılacak “ikinci bir göz” olarak sağlık sistemine değer katmaktır.

KAYNAKLAR

1. Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*. 2017;42:60–88. doi:10.1016/j.media.2017.07.005
2. Razzak MI, Naz S, Zaib A. Deep learning for medical image processing: Overview, challenges and the future. In: Dey N, Ashour AS, Borra S (eds.). *Classification in BioApps: Automation of Decision Making*. Cham: Springer; 2017. p. 323–350. doi:10.1007/978-3-319-65981-7_12
3. Yılmaz İN, Küçük İF, Yıldız İE, et al. Asistan hekimlerin zihinsel yorgunluk deneyimleri üzerine nitel bir araştırma. *Nobel Medicus Journal*. 2024;20(1).
4. Bi WL, Hosny A, Schabath MB, et al. Artificial intelligence in cancer imaging: Clinical challenges and applications. *CA: A Cancer Journal for Clinicians*. 2019;69(2):127–157. doi:10.3322/caac.21552
5. Mamdouh D, Attia M, Osama M, et al. Advancements in radiology report generation: A comprehensive analysis. *Bioengineering*. 2025;12(7):693. doi:10.3390/bioengineering12070693
6. Pacal I, Celik O, Bayram B, et al. Enhancing EfficientNetv2 with global and efficient channel attention mechanisms for accurate MRI-based brain tumor classification. *Cluster Computing*. 2024;27(8):11187–11212. doi:10.1007/s10586-024-04532-1
7. Ibtehaz N, Rahman MS. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks*. 2020;121:74–87. doi:10.1016/j.neunet.2019.08.025
8. Çelik Ö, Tüfekci N. Use of deep learning in clinical decision support systems in healthcare. *Journal of Current Researches on Health Sector*. 2025;15(1):19–32. doi:10.26579/jocrehes.15.1.2
9. Deheyab AOA, Alwan MH, Rezzaqe İKA, et al. An overview of challenges in medical image processing. In: Proceedings of the 6th International Conference on Future Networks & Distributed Systems. 2022, New York. p. 511–516.. doi:10.1145/3584202.3584278
10. Goel N, Yadav A, Singh BM. Medical image processing: A review. In: *Second International Innovative Applications of Computational Intelligence on Power, Energy and Controls with their Impact on Humanity (CIPECH)*. 2016, Ghaziabad, India. p. 57–62. Doi:10.1109/CIPECH.2016.7918737
11. Alnaggar OAMF, Jagadale BN, Saif MAN, et al. Efficient artificial intelligence approaches for

- medical image processing in healthcare: Comprehensive review, taxonomy, and analysis. *Artificial Intelligence Review*. 2024;57(8):221. doi:10.1007/s10462-024-10814-2
12. Ramesh KKD, Kumar GK, Swapna K, et al. A review of medical image segmentation algorithms. *EAI Endorsed Transactions on Pervasive Health and Technology*. 2021;7(27). doi:10.4108/eai.12-4-2021.169184
 13. Deserno TM. Fundamentals of biomedical image processing. In: Deserno TM (ed.). *Biomedical Image Processing*. Berlin, Heidelberg: Springer; 2010. p. 1–51.
 14. Wang J, Zhu H, Wang SH, et al. A review of deep learning on medical image analysis. *Mobile Networks and Applications*. 2021;26(1):351–380. doi:10.1007/s11036-020-01672-7
 15. Anwar SM, Majid M, Qayyum A, et al. Medical image analysis using convolutional neural networks: A review. *Journal of Medical Systems*. 2018;42(11):226. doi:10.1007/s10916-018-1088-1
 16. Matsuzaka Y, Iyoda M. Applications, image analysis, and interpretation of computer vision in medical imaging. *Frontiers in Radiology*. 2025;5:1733003. doi:10.3389/fradi.2025.1733003
 17. Rahman A, Debnath T, Kundu D, et al. Machine learning and deep learning-based approach in smart healthcare: Recent advances, applications, challenges and opportunities. *AIMS Public Health*. 2024;11(1):58. doi:10.3934/publichealth.2024004
 18. Das S, Nayak SP, Sahoo B, et al. Machine learning in healthcare analytics: A state-of-the-art review. *Archives of Computational Methods in Engineering*. 2024;31(7):3923–3962. doi:10.1007/s11831-024-10098-3
 19. Bolhasani H, Mohseni M, Rahmani AM. Deep learning applications for IoT in health care: A systematic review. *Informatics in Medicine Unlocked*. 2021;23:100550. doi:10.1016/j.imu.2021.100550
 20. Abdel-Jaber H, Devassy D, Al Salam A, et al. A review of deep learning algorithms and their applications in healthcare. *Algorithms*. 2022;15(2):71. doi:10.3390/a15020071
 21. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nature Medicine*. 2019;25(1):24–29. doi:10.1038/s41591-018-0316-z
 22. Singh SP, Wang L, Gupta S, et al. 3D deep learning on medical images: a review. *Sensors*. 2020;20(18):5097. doi:10.3390/s20185097
 23. Hasanah SA, Pravitasari AA, Abdullah AS, et al. A deep learning review of ResNet architecture for lung disease identification in CXR image. *Applied Sciences*. 2023;13(24):13111. doi:10.3390/app132413111
 24. Zubair Rahman AM, Mythili R, Chokkanathan K, et al. Enhancing image-based diagnosis of gastrointestinal tract diseases through deep learning with EfficientNet and advanced data augmentation techniques. *BMC Medical Imaging*. 2024;24(1):306. doi:10.1186/s12880-024-01479-y
 25. Zhang H, Qie Y. Applying deep learning to medical imaging: a review. *Applied Sciences*. 2023;13(18):10521. doi:10.3390/app131810521
 26. Abdou MA. Literature review: Efficient deep neural networks techniques for medical image analysis. *Neural Computing and Applications*. 2022;34(8):5791–5812. doi:10.1007/s00521-022-06960-9
 27. Yousef R, Gupta G, Yousef N, et al. A holistic overview of deep learning approach in medical imaging. *Multimedia Systems*. 2022;28(3):881–914. doi:10.1007/s00530-021-00884-5
 28. Cong L, Feng W, Yao Z, et al. Deep learning model as a new trend in computer-aided diagnosis of tumor pathology for lung cancer. *Journal of Cancer*. 2020;11(12):3615. doi:10.7150/jca.43268
 29. Sutton RT, Pincock D, Baumgart DC, et al. An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ Digital Medicine*. 2020;3(1):17. doi:10.1038/s41746-020-0221-y
 30. Antoniadi AM, Du Y, Guendouz Y, et al. Current challenges and future opportunities for XAI in machine learning-based clinical decision support systems: a systematic review. *Applied Sciences*. 2021;11(11):5088. doi:10.3390/app11115088
 31. Mukherjee T, Pournik O, Lim Choi Keung SN, et al. Clinical decision support systems for brain

- tumour diagnosis and prognosis: A systematic review. *Cancers*. 2023;15(13):3523. doi:10.3390/cancers15133523
32. Ogut E. Artificial intelligence in clinical medicine: challenges across diagnostic imaging, clinical decision support, surgery, pathology, and drug discovery. *Clinics and Practice*. 2025;15(9):169. doi:10.3390/clinpract15090169
 33. Shaikh F, Dehmeshki J, Bisdas S, et al. Artificial intelligence-based clinical decision support systems using advanced medical imaging and radiomics. *Current Problems in Diagnostic Radiology*. 2021;50(2):262–267. doi: 10.1067/j.cpradiol.2020.05.006
 34. Tsolaki E, Svolos P, Kousi E, et al. Fast spectroscopic multiple analysis (FASMA) for brain tumor classification: a clinical decision support system utilizing multi-parametric 3T MR data. *International Journal of Computer Assisted Radiology and Surgery*. 2015;10(7):1149–1166. doi:10.1007/s11548-014-1088-7
 35. Gulshan V, Peng L, Coram M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*. 2016;316(22):2402–2410. doi:10.1001/jama.2016.17216
 36. Rodriguez-Ruiz A, Lång K, Gubern-Merida A, et al. Stand-alone artificial intelligence for breast cancer detection in mammography: comparison with 101 radiologists. *JNCI: Journal of the National Cancer Institute*. 2019;111(9):916–922. doi:10.1093/jnci/djy222
 37. Zare S, Mobarak Z, Meidani Z, et al. Effectiveness of clinical decision support systems on the appropriate use of imaging for central nervous system injuries: a systematic review. *Applied Clinical Informatics*. 2022;13(1):37–52. doi:10.1055/s-0041-1740921
 38. Dijk SW, Wollny C, Barkhausen J, et al. Evaluation of a clinical decision support system for imaging requests: a cluster randomized clinical trial. *JAMA*. 2025;333(14):1212–1221. doi: 10.1001/jama.2024.27853
 39. Erukude ST, Marella VC, Veluru SR. Explainable deep learning in medical imaging: Brain tumor and pneumonia detection. In: Proceedings of the 4th International Conference on Innovative Mechanisms for Industry Applications (ICIMIA). 2025. doi: 10.1109/ICIMIA67127.2025.11200629.
 40. Houssein EH, Gamal AM, Younis EM, et al. Explainable artificial intelligence for medical imaging systems using deep learning: a comprehensive review. *Cluster Computing*. 2025;28(7):469. doi: 10.1007/s10586-025-05281-5
 41. Cui L, Fan Z, Yang Y, et al. Deep learning in ischemic stroke imaging analysis: a comprehensive review. *BioMed Research International*. 2022;2022(1):2456550. doi: 10.1155/2022/2456550
 42. Issaiy M, Zarei D, Kolahi S, et al. Machine learning and deep learning algorithms in stroke medicine: a systematic review of hemorrhagic transformation prediction models. *Journal of Neurology*. 2025;272(1):37. doi: 10.1007/s00415-024-12810-6
 43. Zhou SK, Greenspan H, Davatzikos C, et al. A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises. *Proceedings of the IEEE*. 2021;109(5):820–838. doi: 10.1109/JPROC.2021.3054390
 44. Ihongbe E, Fouad S, Mahmoud TE, et al. Evaluating explainable artificial intelligence (XAI) techniques in chest radiology imaging through a human-centered lens. *PLoS One*. 2024;19(10):e0308758. doi: 10.1371/journal.pone.0308758
 45. Muchuchuti S, Viriri S. Retinal disease detection using deep learning techniques: a comprehensive review. *Journal of Imaging*. 2023;9(4):84. doi: 10.3390/jimaging9040084
 46. Suara S, Jha A, Sinha P, et al. Is Grad-CAM explainable in medical images? In: International Conference on Computer Vision and Image Processing. 2023.
 47. Attri N, Mahajan S. Brain tumor detection with explainable AI: A Grad-CAM approach to medical imaging. In: International Conference on Electronics, AI and Computing (EAIC). 2025. doi: 10.1109/EAIC66483.2025.11101626.
 48. Zhang H, Ogasawara K. Grad-CAM-based explainable artificial intelligence related to medical text processing. *Bioengineering*. 2023;10(9):1070. doi: 10.3390/bioengineering10091070
 49. Ray PP. A review on explainable artificial intelligence in radiomics: State-of-the-art tools, pros-

- pective use cases, challenges and future directions. *European Journal of Radiology Artificial Intelligence*. 2025;100069. doi: 10.1016/j.ejrai.2025.100069
50. Ahmed F, Naz NS, Khan S, et al. Explainable artificial intelligence (XAI) in medical imaging: a systematic review of techniques, applications, and challenges. *BMC Medical Imaging*. 2026. doi: 10.1186/s12880-025-02118-w
 51. Brima Y, Atemkeng M. Robustness and scalability of machine learning for imbalanced clinical data in emergency and critical care. *arXiv Preprint*. 2025. doi: 10.48550/arXiv.2512.21602
 52. Agyemang EF, Mensah JA, Nyarko E, et al. Addressing class imbalance problem in health data classification: Practical application from an oversampling viewpoint. *Applied Computational Intelligence and Soft Computing*. 2025;2025(1):1013769. doi: 10.1155/acis/1013769
 53. Garcea F, Serra A, Lamberti F, et al. Data augmentation for medical imaging: A systematic literature review. *Computers in Biology and Medicine*. 2023;152:106391. doi: 10.1016/j.compbiomed.2022.106391
 54. Alzubaidi L, Al-Amidie M, Al-Asadi A, et al. Novel transfer learning approach for medical imaging with limited labeled data. *Cancers*. 2021;13(7):1590. doi: 10.3390/cancers13071590
 55. Yadav N, Pandey S, Gupta A, et al. Data privacy in healthcare: in the era of artificial intelligence. *Indian Dermatology Online Journal*. 2023;14(6):788–792. doi: 10.4103/idoj.idoj_543_23
 56. Goceri E. Medical image data augmentation: techniques, comparisons and interpretations. *Artificial Intelligence Review*. 2023;56(11):12561–12605. doi: 10.1007/s10462-023-10453-z
 57. Li M, Jiang Y, Zhang Y, et al. Medical image analysis using deep learning algorithms. *Frontiers in Public Health*. 2023;11:1273253. doi: 10.3389/fpubh.2023.1273253
 58. Varoquaux G, Colliot O. Evaluating machine learning models and their diagnostic value. In: Colliot O, Varoquaux G (eds.). *Machine Learning for Brain Disorders*. London: Academic Press; 2023. p. 601–630. doi: 10.1007/978-1-0716-3195-9_20
 59. Salehi AW, Khan S, Gupta G, et al. A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope. *Sustainability*. 2023;15(7):5930. doi: 10.3390/su15075930
 60. He K, Zhang X, Ren S, et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016. p. 770–778.
 61. Gu C, Lee M. Deep transfer learning using real-world image features for medical image classification, with a case study on pneumonia X-ray images. *Bioengineering*. 2024;11(4):406. doi: 10.3390/bioengineering11040406
 62. Feurer M, Hutter F. Hyperparameter optimization. In: Hutter F, Kotthoff L, Vanschoren J (eds.). *Automated Machine Learning: Methods, Systems, Challenges*. Cham: Springer; 2019. p. 3–33.
 63. İnik Ö. CNN hyper-parameter optimization for environmental sound classification. *Applied Acoustics*. 2023;202:109168. doi: 10.1016/j.apacoust.2022.109168
 64. Raiaan MAK, Sakib S, Fahad NM, et al. A systematic review of hyperparameter optimization techniques in convolutional neural networks. *Decision Analytics Journal*. 2024;11:100470. doi: 10.1016/j.dajour.2024.100470
 65. Davila A, Colan J, Hasegawa Y. Comparison of fine-tuning strategies for transfer learning in medical image classification. *Image and Vision Computing*. 2024;146:105012. doi: 10.1016/j.imavis.2024.105012
 66. Liang J. Confusion matrix: Machine learning. *POGIL Activity Clearinghouse*. 2022;3(4).
 67. Kocak B, Klontzas ME, Stanzione A, et al. Evaluation metrics in medical imaging AI: fundamentals, pitfalls, misapplications, and recommendations. *European Journal of Radiology Artificial Intelligence*. 2025;100030. doi: 10.1016/j.ejrai.2025.100030
 68. Cabot JH, Ross EG. Evaluating prediction model performance. *Surgery*. 2023;174(3):723–726. doi: 10.1016/j.surg.2023.05.023
 69. Erickson BJ, Kitamura F. Performance metrics for machine learning models. In: *Radiological Society of North America*. 2021.
 70. Hicks SA, Strümke I, Thambawita V, et al. On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*. 2022;12(1):5979. doi: 10.1038/s41598-022-09954-8

BÖLÜM 5

ENGELLİ BİREYLERE SUNULAN SAĞLIK HİZMETLERİ VE REHABİLİTASYONDA MULTİDİSİPLİNER EKİP YAKLAŞIMI

Fatih ORHAN¹
Umur BEYLİK²

GİRİŞ

Kaliteli ve güvenilir bir sağlık hizmetlerine erişim, tüm bireyler için bir temel hak niteliğinde olup dünya nüfusunun yaşlanması ve kronik sağlık sorunlarının artmasıyla birlikte, engelli bireylerin sağlık bakımı ve rehabilitasyonu da giderek daha fazla önem kazanmaktadır (Seyhan ve Şen, 2024). Engelli bireyler hem kendileri ve aileleri için hem de yakın çevreleri için sosyal, kültürel, ekonomik, eğitim ve fırsat eşitliği bağlamında negatif dışsallık yaşayabilmektedir. Bu bağlamda engelli bireylerin yaşam kalitesini artırmak ve bağımsızlıklarını desteklemek için etkili bir sağlık bakımı ve rehabilitasyon yaklaşımı oluşturabilmek amacıyla multidisipliner bir ekip yaklaşımı ile konuyu ele almak hayati bir öneme sahiptir. Son yıllarda, engelli bireylerin sağlıkta yaşadığı eşitsizliklerin azaltılması ve sağlık sistemlerinin engellilik açısından kapsayıcı hale getirilmesi için bütüncül, disiplinler arası ve ekip temelli bakım modellerinin güçlendirilmesi gerektiği vurgulanmaktadır (Kuper ve diğ., 2024; Smythe ve diğ., 2026; World Health Organization, 2024).

Sağlık hizmetlerinin neredeyse tamamı bir ekip çalışmasına dayalıdır yani sağlık hizmetleri iş bölümü, uzmanlaşma ve koordinasyonun son derece yüksek olduğu kompleks hizmetlerdir. Bir sağlık hizmetinin çıktısı diğer sağlık hizmetlerinin girdisi olduğundan sağlık tesisi çatısı altında sunulan hizmetlere ve dolayısıyla

¹ Dr. Öğr. Üyesi, Sağlık Bilimleri Üniversitesi, Gülhane Sağlık Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, fatih.orhan@sbu.edu.tr, ORCID iD: 0000-0002-3562-1961

² Prof. Dr., Sağlık Bilimleri Üniversitesi, Gülhane Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölüm, umut.beylik@sbu.edu.tr, ORCID iD: 0000-0002-4950-9604

KAYNAKLAR

- Africa, L., Frantz, J., & Mlenzana, N. B. (2025). Guidelines for interprofessional practice in rehabilitation at primary health care level. *African Journal of Primary Health Care & Family Medicine*, 17(1), 5079.
- Ali, A., & Hassiotis, A. (2008). Illness in people with intellectual disabilities. *Bmj*, 336(7644), 570-571.
- Arul, U. (2020). 'Access to healthcare facilities among the disabled people towards the public healthcare institution'. *Int. J. Sci. Technol.*
- Ashton, C. M., Haidet, P., Paterniti, D. A., Collins, T. C., Gordon, H. S., O'Malley, K., ... & Street Jr, R. L. (2003). Racial and ethnic disparities in the use of health services: bias, preferences, or poor communication?. *Journal of general internal medicine*, 18(2), 146-152.
- Barr, O. (1997). Interdisciplinary teamwork: consideration of the challenges. *British Journal of Nursing*, 6(17), 1005-1010.
- Baru, R., Acharya, A., Acharya, S., Kumar, A. S., & Nagaraj, K. (2010). Inequities in access to health services in India: caste, class and region. *Economic and political Weekly*, 49-58.
- Betancourt, J. R., Green, A. R., Carrillo, J. E., & Owsu Ananeh-Firempong, I. I. (2016). Defining cultural competence: a practical framework for addressing racial/ethnic disparities in health and health care. *Public health reports*.
- Branigan, M., Stewart, D. E., Tardif, G. S., & Veltman, A. (2001). Perceptions of primary healthcare services among persons with physical disabilities; Part 2: Quality issues. *Medscape General Medicine*, 3(2), 19.
- Byron, M., Howell, C., Bradley, P., Bheenuck, S., Wickham, C., & Curran, T. (2006). Different Differences: Disability equality teaching in healthcare education.
- Copley, J., Martin, R., Dix, C., Forbes, R., Hill, A., Mandrusiak, A., ... & Collins, C. (2024). Fostering collaborative practice through interprofessional simulation for occupational therapy, physiotherapy, dietetics, and nursing students. *Journal of Interprofessional Care*, 38(3), 534-543.
- Dassah, E., Aldersey, H., McColl, M. A., & Davison, C. (2018). Factors affecting access to primary health care services for persons with disabilities in rural areas: a "best-fit" framework synthesis. *Global health research and policy*, 3(1), 1-13.
- Diab, M. E., & Johnston, M. V. (2004). Relationships between level of disability and receipt of preventive health services. *Archives of physical medicine and rehabilitation*, 85(5), 749-757.
- Galvin, R. (2004). Challenging the need for gratitude: Comparisons between paid and unpaid care for disabled people. *Journal of Sociology*, 40(2), 137-155.
- Genet, N., Boerma, W. G., Kringos, D. S., Bouman, A., Francke, A. L., Fagerström, C., ... & Devillé, W. (2011). Home care in Europe: a systematic literature review. *BMC health services research*, 11, 1-14.
- Gibson, J., & O'Connor, R. (2010). Access to health care for disabled people: a systematic review. *Social care and Neurodisability*, 1(3), 21-31.
- Gulliford, M., Figueroa-Munoz, J., Morgan, M., Hughes, D., Gibson, B., Beech, R., & Hudson, M. (2002). What does 'access to health care' mean?. *Journal of health services research & policy*, 7(3), 186-188.
- Güler, E.K., (2005), Tıbbi Ortamların ve İlişkilerin Engelli Kişilere Uygunluğunun Etik Yönden Değerlendirilmesi, Çukurova Üniversitesi, Adana.
- Heath, G. N., & Fentem, P. H. (1997). 8 Physical Activity among Persons with Disabilities—A Public Health Perspective. *Exercise and sport sciences reviews*, 25(1), 195-234.
- Hughes, S. L., Weaver, F. M., Giobbie-Hurder, A., Manheim, L., Henderson, W., Kubal, J. D., ... & Department of Veterans Affairs Cooperative Study Group on Home-Based Primary Care. (2000). Effectiveness of team-managed home-based primary care: a randomized multicenter trial. *Jama*, 284(22), 2877-2885.
- Hwang, K., Johnston, M., Tulskey, D., Wood, K., Dyson-Hudson, T., & Komaroff, E. (2009). Access and coordination of health care service for people with disabilities. *Journal of Disability Policy*

- Studies*, 20(1), 28-34.
- Jones, M., DeRuyter, F., & Morris, J. (2020). The digital health revolution and people with disabilities: perspective from the United States. *International journal of environmental research and public health*, 17(2), 381.
- Kavanagh, A., Dickinson, H., Carey, G., Llewellyn, G., Emerson, E., Disney, G., & Hatton, C. (2021). Improving health care for disabled people in COVID-19 and beyond: lessons from Australia and England. *Disability and health journal*, 14(2), 101050.
- Kobeissi, M. M., & Manning, C. A. (2025). Access enabled: More equitable telehealth for people with disabilities. *The Journal for Nurse Practitioners*, 21(8), 105451.
- Kroll, T., Jones, G. C., Kehn, M., & Neri, M. T. (2006). Barriers and strategies affecting the utilisation of primary preventive services for people with physical disabilities: a qualitative inquiry. *Health & social care in the community*, 14(4), 284-293.
- Kuper, H., Gatta, D. R., Rotenberg, S., Banks, L. M., Smythe, T., & Heydt, P. (2024). Building disability-inclusive health systems. *The Lancet Public Health*, 9(5), e316-e325.
- Kürklü, S., & Kılıç, B. (2026). Geçmişten günümüze hemşirelikte etik konulara ilişkin çalışmaların incelenmesi. *Sağlık Akademisyenleri Dergisi*, 12(4), 674-682.
- Kürklü, S., & Yurdakul, E.S. (2025). Afet Etiği. ISBN: 978-625-375-599-7. Akademisyen Kitabevi.
- Lawthers, A. G., Pransky, G. S., Peterson, L. E., & Himmelstein, J. H. (2003). Rethinking quality in the context of persons with disability. *International Journal for Quality in Health Care*, 15(4), 287-299.
- Lennox, N., Bain, C., Rey-Conde, T., Purdie, D., Bush, R., & Pandeya, N. (2007). Effects of a comprehensive health assessment programme for Australian adults with intellectual disability: a cluster randomized trial. *International journal of epidemiology*, 36(1), 139-146.
- Maart, S., & Jelsma, J. (2014). Disability and access to health care—a community based descriptive study. *Disability and rehabilitation*, 36(18), 1489-1493.
- Mackintosh, S., & Leather, P. (2016). The disabled facilities grant: Before and after the introduction of the better care fund. Foundations: Derbyshire, UK.
- Murphy, J. (2006). Perceptions of communication between people with communication disability and general practice staff. *Health Expectations*, 9(1), 49-59.
- Rohrer, J. E., Wilkinson, J. M., Barnes, D. E., & Adamson, S. C. (2008). Physical limitations and perceived quality of care among family medicine patients. *Clinical Rehabilitation*, 22(3), 283-287.
- Rong, G., Mendez, A., Assi, E. B., Zhao, B., & Sawan, M. (2020). Artificial intelligence in healthcare: review and prediction case studies. *Engineering*, 6(3), 291-301.
- Sapancı, F., (2013), Sağlık Hizmetlerinde Engellilik Kavramı ve Engellilerin Sağlık Hizmetlerinden Yararlanmaları, Beykent Üniversitesi Sosyal Bilimler Enstitüsü Hastane ve Sağlık Kurumları Yönetimi Bilim Dalı, Yüksek Lisans Tezi, İstanbul.
- Seyhan, F. (2023). Sağlık Turizmi ve Geronteknoloji İlişkisi, Orhan, F., Uzunhasanoğlu, G. & Özgök, Y. (Ed.); Geronteknoloji:Multidisipliner Yaklaşımlar, İksad Publishing House.
- Seyhan, F. & Şen, H. (2024). Sağlık kurumlarında Toplam Kalite Yönetimi ve Akreditasyon, Korkmaz, S. & Seyhan, F. (Ed.), Sağlık Kurumları İşletmeciliğinde Temel Konular ve Uygulamalar, Siyasal Kitabevi.
- Smythe, T., Rotenberg, S., Moyo-Chilufya, M., Wilbur, J., & Kuper, H. (2026). Health inequalities among people with disabilities: an umbrella review and evidence synthesis. *EClinicalMedicine*, 91.
- Soltani, S., Takian, A., Sari, A. A., Majdzadeh, R., & Kamali, M. (2017). Cultural barriers in access to healthcare services for people with disability in Iran: A qualitative study. *Medical Journal of the Islamic Republic of Iran*, 31, 51.
- Steel, N., Bachmann, M., Maisey, S., Shekelle, P., Breeze, E., Marmot, M., & Melzer, D. (2008). Self reported receipt of care consistent with 32 quality indicators: national population survey of adults aged 50 or more in England. *Bmj*, 337.
- Şen, H., Kaplan, E. T., & Sağlık, S. (2023). Sağlık sektöründe toplam kalite yönetimi ve insan kaynakları ilişkisi. İksad Publishing House.

- Şen, H., & Üstün, V. (2024). Engelli yaşlı bireylerin sosyal izolasyon ve yalnızlık durumlarının değerlendirilmesi. *Sosyal Beşeri ve İdari Bilimler Dergisi*, 7(7), 529-544.
- Tezzoni, L. I., McCarthy, E. P., Davis, R. B., Harris-David, L., & O'Day, B. (2001). Use of screening and preventive services among women with disabilities. *American Journal of Medical Quality*, 16(4), 135-144.
- Thomé, B., Dykes, A. K., & Hallberg, I. R. (2003). Home care with regard to definition, care recipients, content and outcome: systematic literature review. *Journal of clinical nursing*, 12(6), 860-872.
- Turner-Stokes, L., Williams, H., Abraham, R., & Duckett, S. (2000). Clinical standards for inpatient specialist rehabilitation services in the UK. *Clinical Rehabilitation*, 14(5), 468-480.
- United Nations. (2023). Convention on the rights of persons with disabilities. <https://www.un.org/development/desa/disabilities/convention-on-the-rights-of-persons-with-disabilities.html>
- Waterworth, C. J., Smith, F., Kiefel-Johnson, F., Pryor, W., & Marella, M. (2024). Integration of rehabilitation services in primary, secondary, and tertiary levels of health care systems in low-and middle-income countries: a scoping review. *Disability and rehabilitation*, 46(25), 5965-5976.
- Whittle, R. (2002). The Framework Directive for equal treatment in employment and occupation: an analysis from a disability rights perspective. *European Law Review*, 27(3), 303-326.
- World Health Organization, (2011). The World Report on Disability. 2011. Availableonline: http://www.who.int/disabilities/world_report/2011/en/
- World Health Organization. (2024). Health equity for persons with disabilities: guide for action. World Health Organization.
- Yeung, C. K., Cheng, K. M., Wong, P. K., Wong, S. S., Cheng, H. Y., Cheung, W. Y., ... & Lee, C. C. (2026). An ICF-Based Interdisciplinary Case Management Improves Functioning, Participation, and Well-being for People with Disabilities in Community Rehabilitation: A Protocol for a Randomised Controlled Trial. *Frontiers in Rehabilitation Sciences*, 7, 1745671.
- Zhao, C., Yu, X., Yang, S., & Shao, S. (2021). Utilization of home-based medical services in disabled elderly people in Beijing: a mixed-method study. *Chinese General Practice*, 24(13), 1676.

BÖLÜM 6

BÜTÜNCÜL SAĞLIK HİZMETLERİNDE MANEVİYATIN YÖNETİMSEL ROLÜ: KURAMSAL VE UYGULAMALI BİR ÇERÇEVE

Ali ALU¹

GİRİŞ

Bütüncül sağlık yaklaşımı, insanı biyolojik, bedensel, zihinsel, psiko-sosyal ve manevi boyutlarıyla bütüncül şekilde ele alan bir anlayış olarak tanımlanmaktadır (Eldemir, 2025). Holistik sağlık yaklaşımı ise sağlığı yalnızca hastalık veya sakatlığın yokluğu olarak değil, bireyin bütüncül iyilik hâli içerisinde bulunması olarak açıklamaktadır (Söylemez ve Işık, 2026). Bütüncül sağlık yaklaşımı, fizyolojik, psikolojik, sosyal ve spiritüel (manevi) boyutlar olmak üzere dört ana gruba ayrılmaktadır (Bayındır ve Biçer, 2019). Bu boyutlar arasında özellikle maneviyat, bütüncül sağlık yaklaşımının merkezinde yer almaktadır; çünkü maneviyat, bireyin yaşamının anlamı ve amacı, yaratılışla ilgili sorgulamaları ve ruhsal denge arayışıyla doğrudan ilişkilidir (Söylemez ve Işık, 2026).

Maneviyat, Latince kelime anlamı olarak “nefes, soluk” ve “ruh” gibi kavramları ifade etmektedir. Türk Dil Kurumu tarafından ise manevi kavram, “maddi olmayan şeyler” olarak tanımlanmaktadır (Dinçer vd., 2021). Manevi sağlık, bireyin kendisiyle yaptığı içsel değerlendirmeler ve çevresindeki kişilerle kurduğu ilişkiler aracılığıyla, yaratıcıyla kurduğu bağ üzerinden yaşamına anlam ve amaç kazandırma süreci; bunun yanı sıra içsel denge ve huzur duygusuna ulaşma olarak tanımlanmaktadır (Tuck et al., 2025). Yapılan araştırmalar, maneviyat ile sağlık arasında doğrudan bir ilişki olduğunu göstermektedir. Başka bir deyişle, manevi yönü güçlü olan bireyler, stres ve benzeri ruhsal veya psikolojik zorluklarla başa çıkmada daha başarılı olmaktadır (Dinçer vd., 2021; Karaduman ve Aydın, 2024).

Sağlık kurumlarında işyeri maneviyatı, çalışanların yaptıkları işe aidiyet his-

¹ Dr. Öğr. Üyesi, Aydın Adnan Menderes Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulu, Tıbbi Dokümantasyon ve Sekreterlik Pr., ali.alu@adu.edu.tr, ORCID iD: 0000-0002-7608-2976

KAYNAKLAR

- Akbolat, A. (2022). *Kronik hastalarda iyi oluş ve maneviyat: Nitel bir araştırma* (Doctoral dissertation, Necmettin Erbakan University (Turkey)).
- Atakul, Ş. (2022). İşyeri Maneviyatı ve Örgütsel Adaletin Örgütsel Bağlılık, İş Tatmini ve İşten Ayrılma Niyeti Üzerindeki Etkileri. (Yayınlanmamış Doktora Tezi). İstanbul: İstanbul Sabahattin Zaim Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Bayındır, S. K., & Biçer, S. (2019). Holistik hemşirelik bakımı. *İzmir Kâtip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi*, 4(1), 25-29.
- Çiçek, B., & Kaynak, İ. (2024). İşyerinde mutluluğun anahtarı: Etik iklim ve işyeri maneviyatı. *Malatya Turgut Özal Üniversitesi İşletme ve Yönetim Bilimleri Dergisi*, 5(1), 57-75.
- Dinçer, S., Aydın, K., & Büyükbayram, K. Y. (2021). Çalışma Sosyolojisi Açısından İş Yerinde Maneviyat Hak İş Uluslararası Emek ve Toplum Dergisi, 10(27), 338-362.
- Eldemir, F. (2025). Türk Tıp Tarihindeki Bütüncül Sağlık Yaklaşım Örnekleri. *Journal of Analytic Divinity*, 9(1), 1-23.
- Esendir, N. İ., & Kaplan, H. (2018). Sağlık Çalışanlarının Maneviyat ve Manevi Destek Algısı: İstanbul Örneği. *Ekev Akademi Dergisi*, 7(3), 317-332.
- Giberson, T.R., Resick, C.J. ve Dickson, M.W. (2005). Embedding leader characteristics: An examination of homogeneity of personality and values in organizations. *Journal of Applied Psychology*, 90(5), Washington: ABD.
- Tuck, D., Berger, E., Patlamazoglou, L., & Wiley, J. F. (2025). Positive affect is indirectly related to symptoms of anxiety in tertiary education students via coping resources. *Australian Psychologist*, 60(1), 54-67. <https://doi.org/10.1080/00050067.2024.2379939>
- Ulrich, C. M., Taylor, C., Soeken, K., O'Donnell, P., Farrar, A., Danis, M., & Grady, C. (2010). *Everyday ethics: Ethical issues and stress in nursing practice*. *Journal of Advanced Nursing*, 66(11), 2510-2519
- Söylemez, M. A., & Işık, A. (2026). Yaşlı Sağlığında Holistik Yaklaşım: Spiritualite ve Manevi Destek Uygulamaları. *Toplumsal Politika Dergisi*, (2026).
- Karaduman, F. T., & Aydın, A. R. (2024). Ergen Sorunları ve Başetme Yöntemi Olarak Maneviyat/ Manevi Danışmanlık Akademik Platform İslami Araştırmalar Dergisi, 8(3), 407-432.
- Kaya, A. (2024). Örgütsel Adalet İle İşyeri Maneviyatı Arasındaki İlişkide Algılanan Örgütsel Desteğin Aracı Rolü. *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, 7(2), 159-177.
- Kazempour, F. ve Amin, S. M. (2012). "The Impact of Workplace Spirituality Dimensions on Organizational Citizenship Behaviour Among Nurses with the Mediating Effect of Affective Organizational Commitment". *Journal of Nursing Management*, 20, 1039-1048. DOI: 10.1111/jonm.12025
- Karasaç, A., & Becerikli, S. (2019). Gelenekselin Yeniden Üretimi: Postmodern Zamanın Bütünsel Sağlık Yaklaşımı. *Kurgu*, 27(3), 1-16.
- Martin, K. D., & Cullen, J. B. (2006). Continuities and extensions of ethical climate theory: A meta-analytic review. *Journal of Business Ethics*, 69(2), 175-194.
- Marques, J. (2005). Socializing a capitalistic world: Redefining the bottom line. *Journal of American Academy of Business*, 7(1), 283-287.

BÖLÜM 7

MOTİVASYONUN KURAMSAL ÇERÇEVESİ VE SAĞLIK YÖNETİMİNDEKİ YERİ

Fatma Nuray KUŞCU ŞAHİN¹

1.GİRİŞ

Motivasyon, bireylerin belirli bir amacı gerçekleştirmek için davranışlarını başlatma, sürdürme ve yönlendirme süreci olarak tanımlanır. Çalışma yaşamında motivasyon, yalnızca bireysel performansın artırılması için değil, aynı zamanda örgütsel hedeflere ulaşılabilmesi için de kritik bir unsurdur. İş dünyasının farklı alanlarında olduğu gibi, sağlık sektörü açısından da motivasyon, verimlilik ve hizmet kalitesinin temel belirleyicilerinden biridir. Motivasyon, sağlık çalışanlarının performansı, hizmet kalitesi ve hasta güvenliği üzerinde belirleyici bir rol oynamaktadır.

Çalışanların yüksek motivasyona sahip olmaları, iş doyumlarını ve örgütsel bağlılıklarını artırmakta, tükenmişlik düzeylerini azaltmakta ve mesleki performanslarını yükseltmektedir. Yöneticiler açısından motivasyon, çalışanları ortak amaçlara yönlendirme, takım ruhunu geliştirme ve sağlık hizmetlerinde sürekliliği sağlama noktasında stratejik bir araçtır. İşletme düzeyinde ise motivasyon, sağlık kurumlarının verimliliğini, hasta memnuniyetini ve hizmet kalitesini artırarak rekabet avantajı sağlamasına katkı sunar. Sağlık sektörü, karmaşık ve yoğun çalışma koşullarına sahiptir. Bu nedenle motivasyonun sürdürülebilirliği diğer sektörlere kıyasla daha kritik hale gelmektedir.

Sağlık çalışanlarının motivasyonu, ekonomik, psikososyal ve örgütsel unsurların birlikte ele alınmasını gerektiren çok boyutlu bir yapıya sahiptir. Bu araçlar ekonomik, psikososyal ve sosyal olmak üzere üç grupta değerlendirilebilir. Ekonomik araçlar; ücret, ek ödemeler, primler, performansa dayalı teşvikler ve iş güvencesi gibi unsurları kapsar. Sağlık çalışanları için özellikle ücretlendirme,

¹ Dr. Öğr. Üyesi, Hatay Mustafa Kemal Üniversitesi, Hatay Sağlık Hizmetleri Meslek Yüksekokulu, fatmanuraykuscusu@mku.edu.tr, ORCID iD: 0000-0003-2657-6174

yalnızca bireysel çıktıları değil, aynı zamanda hasta güvenliği ve hizmet kalitesini de doğrudan etkilemektedir. Bu nedenle motivasyon, sağlık sektöründe yalnızca bireysel bir unsur değil, kurumsal sonuçlar doğuran önemli bir faktör olarak ele alınmalıdır.

İncelenen kapsam ve süreç teorileri, motivasyonun farklı yönlerini açıklamada önemli katkılar sunmaktadır. Kapsam teorileri çalışanların hangi ihtiyaçlar doğrultusunda motive olduğunu ortaya koyarken, süreç teorileri motivasyonun nasıl oluştuğunu ve sürdürüldüğünü açıklamaktadır. Bununla birlikte sağlık sektörünün kendine özgü yapısı, bu teorilerin tek başına yeterli olmadığını göstermektedir. Özellikle iş yükü, stres, tükenmişlik ve duygusal emek gibi faktörler, motivasyonun çok boyutlu bir yapı içinde değerlendirilmesini gerektirmektedir.

Sağlık çalışanlarının motivasyonu, yalnızca ekonomik araçlarla açıklanabilecek bir olgu değildir. Ücret, ödül ve teşvik sistemleri önemli olmakla birlikte, çalışanların değer görmesi, adil bir yönetim anlayışı, destekleyici bir çalışma ortamı ve mesleki gelişim olanakları da motivasyon üzerinde belirleyici olmaktadır. Bu durum, motivasyonun hem içsel hem de dışsal faktörlerin etkileşimiyle şekillendiğini göstermektedir.

Yönetim açısından değerlendirildiğinde, sağlık kurumlarında çalışan motivasyonunun sürdürülebilir biçimde sağlanabilmesi için bütüncül bir yaklaşım benimsenmelidir. Yöneticilerin çalışanların bireysel farklılıklarını dikkate alması, iletişim kanallarını açık tutması ve çalışanları karar süreçlerine dahil etmesi motivasyonu artırıcı önemli unsurlar arasında yer almaktadır. Ayrıca çalışma koşullarının iyileştirilmesi ve iş yükünün dengelenmesi de motivasyonun korunmasında etkili olmaktadır.

Sonuç olarak motivasyon, sağlık kurumlarında hizmet kalitesini ve örgütsel başarıyı doğrudan etkileyen temel bir değişkendir. Bu nedenle sağlık yönetiminde motivasyonu destekleyen uygulamaların geliştirilmesi, yalnızca çalışan performansını değil, aynı zamanda hasta memnuniyetini ve hizmetin etkinliğini de artıracaktır. Bu nedenle motivasyon, sağlık yönetiminde stratejik bir yönetim aracı olarak ele alınmalıdır.

KAYNAKLAR

- Aktaş, A. (2002). *Turizm İşletmeciliği Ve Yönetimi*. (2. Baskı). Azim Matbaa.
- Alkış, H., & Öztürk, Y. (2009). Otel İşletmelerinde Motivasyon Faktörleri Üzerine Bir Araştırma. *Elektronik Sosyal Bilimler Dergisi*, 8, 212–236.
- Arslanoğlu, Ş. (2016). *Lise müdürlerinde liderlik, liderlik düzeylerinin öğretmenlerin motivasyonuna etkisi (Konya ili örneği)*. KTO Karatay Üniversitesi.
- Aslan, M., & Doğan, S. (2020). Dışsal motivasyon, içsel motivasyon ve performans etkileşimine kuramsal bir bakış. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 11(26), 291–301.

- Aslanadam, B. (2011). *Sağlık Personelinin Motivasyonu ve Buna İlişkin Araştırma*. Dokuz Eylül Üniversitesi.
- Aykanat, S. (2003). *Sağlık İşletmelerinde Personelin Motivasyonunu etkileyen Faktörler*. Gazi Üniversitesi.
- Bakan, İ., Büyükbeşe, T., Erşahan, B., & Kefe, İ. (2013). Kadın Çalışanların Yöneticilere İlişkin Algıları: Bir Alan Çalışması. *Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3, 71–84.
- Barlı, Ö. (2008). *Davranış Bilimleri Ve Örgütlerde Davranış (3. Baskı)*. Aktif Yayınevi.
- Barutçugil, İ. (2004). *Organizasyonlarda Duyguların Yönetimi*. Kariyer Yayınları, 2. Baskı.
- Çelik, M., & Tepe, M. (2021). Stres ve Motivasyon İlişkisi: Kadın Sağlık Çalışanları Örneği. *Al Farabi Uluslararası Sosyal Bilimler Dergisi*, 1(43), 61.
- Çeltik, E. (2004). Motivasyon yönetimi. *İş Güç Endüstri İlişkileri ve İnsan Kaynakları Dergisi*, 6(1), 182.
- Charles, M. C. (2005). A historical view of Douglas McGregor's Theory Y. *Management Decision, Emerald Group Publishing Limited*, 43(3), 450–460.
- Erdoğan, E., & Kaya, E. (2024). COVID-19 Pandemisinde Sağlık Çalışanlarının Tükenmişlik ve Mesleki Motivasyon Düzeylerinin İncelenmesi. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 13(4), 1527–1543.
- Eren, E. (2000). *Örgütsel Davranış Ve Yönetim Psikolojisi, (6. Baskı)*. Beta Basın Yayım Dağıtım.
- Ergül, H. F. (2005). Motivasyon ve Motivasyon Teknikleri. *Elektronik Sosyal Bilimler Dergisi*, 4(14), 67–79.
- Ergün, E. (2022). *Çağrı merkezlerindeki takım liderlerinin müşteri temsilcilerinin motivasyonuna etkisi*. Avrasya Üniversitesi.
- Faridi, K., Mohamadi, M. A., Mehri, S., & Dadkhah, B. (2025). Assessing the relationship between happiness and professional autonomy among clinical nurses: an analytical cross-sectional study. *BMC Nursing*, 24(1), 320. <https://doi.org/10.1186/s12912-025-02989-y>
- Genç, N. (2008). *Yönetim ve Organizasyon*.
- Gu, Y., Zhu, Y., & Xu, G. (2022). Factors associated with mental health outcomes among health care workers in the Fangcang shelter hospital in China. *International Journal of Social Psychiatry*, 68(1), 64–72. <https://doi.org/10.1177/0020764020975805>
- Izgar, H. (2014). *Endüstri ve örgüt psikolojisi*. Eğitim Yayınevi.
- İzgi, H. (2016). *Sağlık kurumu çalışanlarında motivasyonun verimliliğe etkisi (Adana İl Sağlık Müdürlüğü örneği)*. Toros Üniversitesi.
- Karahan, S. (2013). *İçsel Pazarlama Faaliyetlerinin İşgören Tatmini Üzerindeki Etkisi: Otel İşletmelerine Yönelik Bir Uygulama*. Gazi üniversitesi.
- Keser, A. (2006). *Çalışma Yaşamında Motivasyon*. Alfa Aktüel Yayınları.
- Keser, A. (2019). *Çalışma Yaşamında Motivasyon*. Umuttepe Yayınları.
- Koçel, T. (2013). Yönetim ve Organizasyonlarda Davranış Klasik Modern-Çağdaş ve Güncel Yaklaşımlar. In *İşletme Yöneticiliği*. Beta Yayınları 14. Baskı.
- Koçel, T. (2018). Yönetim ve Organizasyonlarda Davranış Klasik Modern-Çağdaş ve Güncel Yaklaşımlar. In *İşletme Yöneticiliği*. Beta Yayınları 18. Baskı.
- Köksal, Ç., Mumcu, G., & Ocak, S. (2023). Örgütsel performansın artışında çalışan motivasyonunun rolü. *Medipol Üniversitesi Sosyal Bilimler Dergisi*, 8, 39–42.
- Kolaylı, G., & Lorcü, F. (2017). Performansa Dayalı Ücret Sistemi ve Hekimlerin Motivasyon Alguları Arasındaki İlişkinin İncelenmesi. *Uluslararası Sağlık Yönetimi ve Stratejileri Dergisi*, 3(3), 340-353.
- Kum, A. (2017). *Sağlık Kurumlarında Çalışan Personelin Motivasyonu*. Beykent Üniversitesi.
- Labrague, L. J. (2024). Relationship between transformational leadership, adverse patient events, and nurse-assessed quality of care in emergency units: The mediating role of work satisfaction. *Australasian Emergency Care*, 27(1), 49-56. <https://doi.org/10.1016/j.auec.2023.08.001>
- Lai, J., Ma, S., Wang, Y., Cai, Z., Hu, J., Wei, N., & Hu, S. (2020). Factors associated with mental health outcomes among health care workers exposed to coronavirus disease 2019. *JAMA Network*

- Open, 3(3), e203976-e203976. <https://doi.org/10.1001/jamanetworkopen.2020.3976>
- McGregor, D. (1960). *The Human Side of Enterprise*. McGraw-Hill.
- Mülayim, A. B. (2015). *Özel ve kamu sağlık kurumu yöneticilerinin motivasyonunu etkileyen faktörler (Muğla ili örneği)*. Beykent Üniversitesi.
- Nayebi, N., Cheraghi, P., & Nasari, Z. (2026). The relationship between professional autonomy and job satisfaction among nurses: A cross-sectional study. *Journal of Nursing Advances in Clinical Sciences*, 3(3), 136–141. <https://doi.org/10.32598/JNACS.2025.1226>
- Öğüt, A., Akgemci, T., & Demirsel, M. T. (2004). Stratejik insan kaynakları yönetimi bağlamında örgütlerde işgören motivasyonu süreci. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12, 277–290.
- Oğuzhan, Y. (2023). Hizmetkar Liderlik ve Motivasyon Temaları Üzerine Vosviewer ile Bibliyometrik Bir Analiz. *Parion Akademik Bakış Dergisi*, 2(1), 1–13.
- Özalp, E., & Kirel, Ç. (2011). *Örgütsel Davranış* (pp. 277-333.). Ekin Basım Yayın Dağıtım.
- Riggio, R. (2016). *Endüstri ve Örgüt Psikolojisine Giriş 6. Baskı*. (Ç. B. Özkara (ed.)). Nobel Yayınları.
- Rutherford, A. (2009). *Beyond the Box: BF Skinner's technology of behaviour from laboratory to life, 1950s-1970s*. University of Toronto Press.
- Saruhan, Ş. C., & Yıldız, M. L. (2017). *Çağdaş yönetim bilimi*. Beta Basım Yayın Dağıtım.
- Saygılı, M., Avcı, K., & Sönmez, S. (2020). Quality of work life and burnout in healthcare workers in Turkey. *Journal of Health Management*, 22(3), 317-329.
- Şemsioğlu, D. (2020). *Örgütsel ve yönetsel düzeyde motivasyon kavramı ve teorileri*. İstanbul Esenyurt Üniversitesi.
- Senbetu, B. D., Debancho, W. W., Jemaneh, T. M., Jima, S. A., Hardido, T. G., & Gerete, T. B. (2025). Work motivation and associated factors among nurses working in public hospitals of the Wolaita Zone, Southern Ethiopia. *Frontiers in Health Services*, 5, 1561643. <https://doi.org/10.3389/frhs.2025.1561643>
- Sevinç, H. (2015). Kamu çalışanlarının motivasyonunda kullanılan araçlar. *Uluslararası Sosyal Yardımlaşmalar Dergisi*, 8(39), 944–964.
- Shanafelt, T., Ripp, J., & Trockel, M. (2020). Understanding and addressing sources of anxiety among health care professionals during the COVID-19 pandemic. *Jama*, 323(21), 2133–2134. <https://doi.org/doi:10.1001/jama.2020.5893>
- Skinner, B. F. (1938). *The behavior of organisms*. Appleton-Century-Crofts.
- Specchia, M. L., Cozzolino, M. R., Carini, E., Di Pilla, A., Galletti, C., Ricciardi, W., & Damiani, G. (2021). Leadership styles and nurses' job satisfaction. Results of a systematic review. *International Journal of Environmental Research and Public Health*, 18(4), 1552. <https://doi.org/10.3390/ijerph18041552>
- Suciu, L., Mortan, M., & Lazar, L. (2013). Vroom's expectancy theory. An empirical study: Civil servant's performance appraisal influencing expectancy. *Transylvanian Review of Administrative Sciences*, 9(39), 180–200.
- Süral, F., & Topaloğlu, E. (2012). *Örgütsel Davranış*. Beta Yayınları.
- Taşpınar, F. (2006). *Motivasyon araçlarının işgören motivasyonu üzerindeki etkisi: Afyonkarahisar ilindeki termal otel işletmelerinde bir araştırma*. Afyon Kocatepe Üniversitesi.
- Tevrüz, S., Erdem, İ., & Bozkurt, T. (2012). *Davranışlarımızdan Seçmeler Örgütsel Davranış*. Nobel Yayınevi 3. Baskı.
- Thorndike, E. L. (1898). Animal intelligence: An experimental study of the associative processes in animals. *Psychological Review Monograph Supplements*, 5(6), 551–570.
- Tim, H. (2003). *Guide to Management Ideas and Gurus*. The Economist, Profile Books.
- Tiryaki, A. (2008). *İşletmelerde Modern Liderlik Yaklaşımları Ve Çalışan Motivasyonu İlişkisine Yönelik Bir Uygulama*. Yıldız Teknik Üniversitesi.
- Trillo, A., Ortega-Maldonado, A., Lopez-Pena, B., & Bretones, F. D. (2025). Psychosocial predictors of job satisfaction in nursing: Insights from a Spanish hospital setting. *Behavioral Sciences*, 15(3), 274. <https://doi.org/10.3390/bs15030274>
- Tutar, H., & Erdönmez, C. (2007). *İşletme Becerileri Grup Çalışması*.

- Ulukoş, K. S. (2016). Motivasyon Teorileri ve Lider Yöneticilik Unsurlarının Bireylerin Motivasyonuna Etkisi. *Akademik Sosyal Araştırmalar Dergisi*, 4(25), 247–262.
- Varghese, B., Joseph, C. M., Al-Akkam, A. A. A., AL-Balawi, R.M.D.O.A., Swallmeh, E., & Singh, K. (2023). Nurse's experience working 12-hour shift in a tertiary level hospital in Qatar: a mixed method study. *BMC Nursing*, 22(1), 213. <https://doi.org/10.1186/s12912-023-01371-0>
- Yasin, Y. M., Alomari, A., Al-Hamad, A., & Kehyayan, V. (2024). The impact of COVID-19 on nurses' job satisfaction: a systematic review and meta-analysis. *Frontiers in Public Health*, 11, 1285101. <https://doi.org/10.3389/fpubh.2023.1285101>
- Yeşil, A. (2016). Liderlik ve Motivasyon Teorilerine Yönelik Kavramsal Bir İnceleme. *Uluslararası Akademik Yönetim Bilimleri Dergisi*, 2(3), 158–180.
- Yılmaz, M. (2014). *Ortaokul Öğretmenlerinin Güdülenme ve İş Doyumu Düzeyleri Arasındaki İlişki*. Adnan Menderes Üniversitesi.

BÖLÜM 8

SAĞLIK YÖNETİMİ ARAŞTIRMALARINDA MAKİNE ÖĞRENİMİ UYGULAMASI: TAHMINE DAYALI ANALİTİKTE ÖĞRENEN SAĞLIK SİSTEMLERİNE

Nurettin ÖNER¹

1. GİRİŞ

Sağlık yönetimi; finansman, kalite, insan kaynakları ve sağlık bilişimi gibi birbirine bağlı alt alanları kapsayan disiplinlerarası bir alandır. Türkiye’de sağlık idaresi veya sağlık kurumları yönetimi gibi farklı adlandırmalar kullanılsa da, bunların tamamı aynı disiplinin farklı odaklarını yansıtmaktadır ve uluslararası yazında Sağlık Yönetimi Araştırmaları (SYA) veya Health Services Research (HSR) olarak tanımlanmaktadır. (National Academies of Sciences & Medicine, 1994).

SYA, bireysel sağlığın geliştirilmesi, toplum sağlığının artırılması ve kişi başına maliyetlerin düşürülmesine odaklanan disiplinlerarası bir alan olarak tanımlanır (Lohr & Steinwachs, 2002; National Academies of Sciences & Medicine, 1994)). SYA, geleneksel olarak araştırma hipotez ve sorularını test etmek için özellikle doğrusal ve lojistik regresyon olmak üzere sıkça kullanılan istatistiksel yöntemlere dayanır (Bowling, 2014). Güçlü ve yorumlanabilir olmalarına karşın, bu yaklaşımlar günümüz sağlık verilerinin karmaşık ve heterojen yapısına cevap vermekte yetersiz kalmaktadır (Doupe et al., 2019; Miotto et al., 2018; Ngiam & Khor, 2019).

Makine öğrenmesi, klasik doğrusal modellemenin bazı temel sınırlılıklarını gidermektedir. Geleneksel regresyon yöntemleri, analistlerin etkileşim terimleri ve fonksiyonel biçimleri önceden belirlemesini zorunlu kılar; bu durum, sağlık verileri büyük ölçekli olduğunda, ilişkiler doğrusal olmadığında veya heterojenlik gösterdiğinde kurulan modelin hatalı sonuçlar vermesine neden olabilir (Jones et al., 2025). Buna karşılık, Random Forest ve Gradient Boosting gibi makine öğrenmesi yöntemleri, açık bir ön tanımlama olmaksızın doğrusal olmayan etkiler

¹ Dr. Öğr. Üyesi, Ankara Üniversitesi, Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölümü, noner@ankara.edu.tr, ORCID iD: 0000-0002-4761-7863.

Bilgi Üretimi: ML modellerinin bu verileri analiz ederek risk profillerini ve tedavi yönergelerini güncellemesi.

Uygulama: Verinin bakım noktasında klinisyenlere sunulması ve böylece karıta dayalı karar vermenin desteklenmesi.

Bu geçiş, hekim güvenini gözeten güçlü klinik karar destek sistemlerini gerektirir. Bu modeller statik uyarılardan uyarılabilir, gerçek zamanlı tanısal yardımcılarına dönüştükçe, hastanelerin hasta akışını yönetme, kaynakları optimize etme ve yüksek değerli bakım sunma biçimlerini temelden değiştirecektir (Susanto et al., 2023).

Disiplinler Arası İş Birliğinin Zorunluluğu

SYA'da makine öğreniminin vaat ettiği potansiyel, veri bilimcilerin tek başına çalışmasıyla gerçekleştirilemez. Biyolojik mekanizmalar, sistem seviyesindeki politikalar ve hasta davranışları arasındaki sağlık hizmetlerinin karmaşıklığı, disiplinlerarası bir yaklaşımı zorunlu kılar. Etkili uygulama, şu aktörler arasında ortak bir dil oluşturmayı gerektirir:

Veri Bilimciler: Teknik titizliği ve algoritmik uzmanlığı sağlar.

Klinisyenler: Alan bilgisini, iş akışı bilgilerini ve klinik doğrulamayı sağlar.

Sağlık Yöneticileri ve Sağlık Yönetimi Uzmanları: Modellerin kurumsal amaçlarla, etik standartlarla ve sistem düzeyindeki sağlık eşitliği hedefleriyle uyumlu olmasını sağlar.

Sonuç olarak, makine öğrenmesi sağlık yönetimi araştırmalarında giderek daha merkezi bir konum kazandıkça, başarı algoritmik karmaşıklıktan çok bu sistemleri destekleyen insan odaklı altyapının niteliğine bağlı olacaktır. Farklı meslek grupları arasındaki ayrışmanın azaltılması ve yorumlanabilirlik, hakkaniyet ile nedenselliğin önceliklendirilmesi, araştırma topluluğunun veriyi kullanarak daha adil, daha verimli ve daha duyarlı bir sağlık sistemi geliştirmesine yardımcı olacaktır.

KAYNAKLAR

- Agrawal, R., & Prabakaran, S. (2020). Big data in digital healthcare: lessons learnt and recommendations for general practice. *Heredity*, 124(4), 525-534.
- Ahmed, A., Zengul, F. D., Khan, S., Heard, K. R., Feldman, S. S., & Hall, A. G. (2024). Developing a decision model to early predict ICU admission for COVID-19 patients: A machine learning approach. *Intell Based Med*, 9, 100136.
- Al-Nafjan, A., Aljuhani, A., Alshebel, A., Alharbi, A., & Alshehri, A. (2025). Artificial intelligence in predictive healthcare: A systematic review. *J Clin Med*, 14(19), 6752.
- Beaulieu-Jones, B., Finlayson, S. G., Chivers, C., Chen, I., McDermott, M., & Kandola, J. (2019). Trends and focus of machine learning applications for health research. *JAMA Netw Open*, 2(10).
- Blanco, J., Ferreras, M., & Cosido, O. (2025). Predictive modeling of hospital emergency department

- demand using artificial intelligence: A systematic review. *Int J Med Inform*, 106215.
- Bowling, A. (2014). *Research methods in health: investigating health and health services*. McGraw-Hill Education (UK).
- Breiman, L. (2001). Random forests. *Mach Learn*, 45(1), 5-32.
- Brusco, N. K., & Watts, J. J. (2015). Empirical evidence of recall bias for primary health care visits. *BMC Health Serv Res*, 15(1), 381.
- Chandrasekaran, R., Sadiq, T. M., & Moustakas, E. (2025). Usage trends and data sharing practices of healthcare wearable devices among US adults: cross-sectional study. *J Med Internet Res*, 27.
- Chen, R. J., Wang, J. J., Williamson, D. F. K., Chen, T. Y., Lipkova, J., & Lu, M. Y. (2023). Algorithmic fairness in artificial intelligence for medicine and healthcare. *Nat Biomed Eng*, 7(6), 719-742.
- de Ruijter, U. W., Kaplan, Z. L. R., & Bramer, W. M. (2022). Prediction Models for Future High-Need High-Cost Healthcare Use: a Systematic Review. *J Gen Intern Med*, 37, 1763-1770.
- Delen, D. (2012). *Practical Text Mining and Statistical Analysis for Non-structured Text Data Applications*.
- Doupe, P., Faghmous, J., & Basu, S. (2019). Machine learning for health services researchers. *Value Health*, 22(7), 808-815.
- Dwivedi, R., Dave, D., Naik, H., Singhal, S., Omer, R., & Patel, P. (2023). Explainable AI (XAI): Core ideas, techniques, and solutions. *ACM Comput Surv*, 55(9), 1-33.
- Eckhardt, C. M., Madjarova, S. J., Williams, R. J., Ollivier, M., Karlsson, J., Pareek, A., & Nwachukwu, B. U. (2023). Unsupervised machine learning methods and emerging applications in healthcare. *Knee Surg Sports Traumatol Arthrosc*, 31(2), 376-381.
- Ellis, L. A., Sarkies, M., Churruca, K., Dammery, G., Meulenbroeks, I., & Smith, C. L. (2022). The science of learning health systems: scoping review of empirical research. *JMIR Med Inform*, 10(2).
- Feretakis, G., Sakagianni, A., Kalles, D., Loupelis, E., Tzelves, L., & Panteris, V. (2022, 2022). Exploratory clustering for emergency department patients. In: *Advances in Informatics, Management and Technology in Healthcare*,
- Finnegan, H., & Mountford, N. (2025). 25 years of electronic health record implementation processes: scoping review. *J Med Internet Res*, 27.
- Fridgeirsson, E. A., Williams, R., Rijnbeek, P., Suchard, M. A., & Reys, J. M. (2024). Comparing penalization methods for linear models on large observational health data. *J Am Med Inform Assoc*, 31(7), 1514-1521.
- Friedman, J. H., Hastie, T., & Tibshirani, R. (2010). Regularization paths for generalized linear models via coordinate descent. *J Stat Softw*, 33, 1-22.
- Gopukumar, D., Ghoshal, A., & Zhao, H. (2022). Predicting readmission charges billed by hospitals: machine learning approach. *JMIR Med Inform*, 10(8).
- Gordon, B., Barrett, J., Fennessy, C., Cake, C., Milward, A., & Irwin, C. (2021). Development of a data utility framework to support effective health data curation. *BMJ Health Care Inform*, 28(1).
- Grant, R. W., McCloskey, J., Hatfield, M., Uratsu, C., Ralston, J. D., Bayliss, E., & Kennedy, C. J. (2020). Use of latent class analysis and k-means clustering to identify complex patient profiles. *JAMA Netw Open*, 3(12).
- Hajek, A. M. (2013). Breaking down clinical silos in healthcare. *Front Health Serv Manag*, 29(4), 45-50.
- Haneuse, S. (2016). Distinguishing Selection Bias and Confounding Bias in Comparative Effectiveness Research. *Med Care*.
- Haripriya, G., Abinaya, K., Aarthi, N., & Praveen Kumar, P. (2021). Random forest algorithms in health care sectors: a review of applications. In.
- Hastie, T., Tibshirani, R., & Friedman, J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- Herawati, N., Nisa, K., Setiawan, E., Nusyirwan, N., & Tiryono, T. (2018). Regularized multiple regression methods to deal with severe multicollinearity. *Int J Stat Appl*, 8(4), 167-172.
- Hlatky, M. A., Winkelmayr, W. C., & Setoguchi, S. (2013). Epidemiologic and statistical methods

- for comparative effectiveness research. *Heart Fail Clin*, 9(1), 29-36.
- Hoerl, A. E., & Kennard, R. W. (1970). Ridge regression: applications to nonorthogonal problems. *Technometrics*, 12(1), 69-82.
- Howard, K. A., Anderson, W., Podichetty, J. T., Gould, R., Boyce, D., & Dasher, P. (2025). Wrangling Real-World Data: Optimizing Clinical Research Through Factor Selection with LASSO Regression. *Int J Environ Res Public Health*, 22(4), 464.
- Huang, K., Altosaar, J., & Ranganath, R. (1904). *ClinicalBERT: Modeling clinical notes and predicting hospital readmission*.
- Huang, Y., Talwar, A., Chatterjee, S., & Aparasu, R. R. (2021). Application of machine learning in predicting hospital readmissions: a scoping review of the literature. *BMC Med Res Methodol*, 21(1), 96.
- Huston, P., & Naylor, C. D. (1996). Health services research: reporting on studies using secondary data sources. *CMAJ*, 155(12), 1697.
- Hyer, J. M., Ejaz, A., Tsilimigras, D. I., Paredes, A. Z., Mehta, R., & Pawlik, T. M. (2019). Novel Machine Learning Approach to Identify Preoperative Risk Factors Associated With Super-Utilization of Medicare Expenditure Following Surgery. *JAMA Surg*, 154(11), 1014-1021.
- Jones, L., Barnett, A., & Vagenas, D. (2025). Linear regression reporting practices for health researchers, a cross-sectional meta-research study. *PLOS ONE*, 20(3).
- Kan, H. J., Kharrazi, H., Chang, H. Y., Bodycombe, D., Lemke, K., & Weiner, J. P. (2019). Exploring the use of machine learning for risk adjustment: A comparison of standard and penalized linear regression models in predicting health care costs in older adults. *PLOS ONE*, 14(3).
- Kaushal, A., Altman, R., & Langlotz, C. (2020). Geographic Distribution of US Cohorts Used to Train Deep Learning Algorithms. *JAMA*, 324(12), 1212-1213.
- Khare, S. R., & Vedel, I. (2019). Recall bias and reduction measures: an example in primary health care service utilization. *Fam Pract*, 36(5), 672-676.
- Kolluri, J., Kotte, V. K., Phridviraj, M. S. B., & Razia, S. (2020, 2020). Reducing overfitting problem in machine learning using novel L1/4 regularization method. In: 2020 4th International Conference on Trends in Electronics and Informatics (ICOEI),
- Krumholz, H. M., Terry, S. F., & Waldstreicher, J. (2016). Data acquisition, curation, and use for a continuously learning health system. *JAMA*, 316(16), 1669-1670.
- Kulkarni, S., Ambekar, S. S., & Hudnurkar, M. (2021). Predicting the inpatient hospital cost using a machine learning approach. *Int J Innov Sci*, 13(1), 87-104.
- Liu, F., & Panagiotakos, D. (2022). Real-world data: a brief review of the methods, applications, challenges and opportunities. *BMC Med Res Methodol*, 22(1), 287.
- Lohr, K. N., & Steinwachs, D. M. (2002). Health services research: An evolving definition of the field. *Health Serv Res*, 37(1), 15.
- Lourenço, L., Weber, L., Garcia, L., Ramos, V., & Souza, J. (2024). Machine Learning Algorithms to Estimate Propensity Scores in Health Policy Evaluation: A Scoping Review. *Int J Environ Res Public Health*, 21(11), 1484.
- Lu, J., Sattler, A., Wang, S., Khaki, A. R., Callahan, A., & Fleming, S. (2022). Considerations in the reliability and fairness audits of predictive models for advance care planning. *Front Digit Health*, 4, 943768.
- Mackin, S., Major, V. J., Chunara, R., & Newton-Dame, R. (2025). Identifying and mitigating algorithmic bias in the safety net. *NPJ Digit Med*, 8(1), 335.
- Martinez, R. G., & Van Dongen, D. M. (2023). Deep learning algorithms for the early detection of breast cancer: A comparative study with traditional machine learning. *Inform Med Unlocked*, 4(1), 101317.
- Mavrogiorgou, A., Kiourtis, A., Kleftakis, S., Mavrogiorgos, K., Zafeiropoulos, N., & Kyriazis, D. (2022). A catalogue of machine learning algorithms for healthcare risk predictions. *Sensors*, 22(22), 8615.
- McGinnis, J. M., Fineberg, H. V., & Dzau, V. J. (2021). Advancing the learning health system. *N Engl J Med*, 385(1), 1-5.

- Menze, B. H., Kelm, B. M., Masuch, R., Himmelreich, U., Bachert, P., Petrich, W., & Hamprecht, F. A. (2009). A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. *BMC Bioinformatics*, 10(1), 213.
- Mihaylova, B., Briggs, A., O'Hagan, A., & Thompson, S. G. (2011). Review of statistical methods for analysing healthcare resources and costs. *Health Econ*, 20(8), 897-916.
- Miner, G. D., Miner, L. A., Goldstein, M., Nisbet, R., Walton, N., & Bolding, P. (2014). *Practical predictive analytics and decisioning systems for medicine: Informatics accuracy and cost-effectiveness for healthcare administration and delivery including medical research*. Academic Press.
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Brief Bioinform*, 19(6), 1236-1246.
- Morris, Z. S., Wooding, S., & Grant, J. (2011). The answer is 17 years, what is the question: understanding time lags in translational research. *J R Soc Med*, 104(12), 510-520.
- Munro, B. H. (2005). *Statistical methods for health care research*. Lippincott Williams & Wilkins.
- Nabrawi, E., & Alanazi, A. (2023). Fraud detection in healthcare insurance claims using machine learning. *Risks*, 11(9), 160.
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Front Neurobot*, 7, 63623.
- National Academies of Sciences, E., & Medicine. (1994). *Health Services Research: Opportunities for an Expanding Field of Inquiry: An Interim Statement*. National Academies Press (US).
- Newman-Griffis, D. R., Hurwitz, M. B., McKernan, G. P., Houtrow, A. J., & Dicianno, B. E. (2022). A roadmap to reduce information inequities in disability with digital health and natural language processing. *PLOS Digit Health*, 1(11).
- Ngiam, K. Y., & Khor, W. (2019). Big data and machine learning algorithms for health-care delivery. *Lancet Oncol*, 20(5).
- Nohara, Y., Matsumoto, K., Soejima, H., & Nakashima, N. (2022). Explanation of machine learning models using shapley additive explanation and application for real data in hospital. *Comput Methods Programs Biomed*, 214, 106584.
- Norori, N., Hu, Q., Aellen, F. M., Faraci, F. D., & Tzovara, A. (2021). Addressing bias in big data and AI for health care: A call for open science. *Patterns (N Y)*, 2(10), 100347.
- Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453.
- Olaya, B., Moneta, M. V., Caballero, F. F., Tyrovolas, S., Bayes, I., Ayuso-Mateos, J. L., & Haro, J. M. (2017). Latent class analysis of multimorbidity patterns and associated outcomes in Spanish older adults: a prospective cohort study. *BMC Geriatr*, 17(1), 186.
- Olson, D. L., & Delen, D. (2008). *Advanced data mining techniques*. Springer Science & Business Media.
- Oner, N., Zengul, F. D., & Agirbas, I. (2024). Evaluation of the financial distress of hospitals through machine learning: An application of AI in healthcare industry. *Intell Syst Account Finance Manag*, 31(4).
- Orhan, F., & Kurtukan, M. N. (2025). Predicting total healthcare demand using machine learning: separate and combined analysis of predisposing, enabling, and need factors. *BMC Health Serv Res*, 25, 366.
- Panch, T., Szolovits, P., & Atun, R. (2018). Artificial intelligence, machine learning and health systems. *J Glob Health*, 8(2), 020303.
- Panga, N. K. R. (2021). Financial fraud detection in healthcare using machine learning and deep learning techniques. *Int J Manag Res Bus Strateg*, 11(3), 46-66.
- Park, J. H., Jo, H. S., Lee, S. H., Oh, S. W., & Na, M. G. (2022). A reliable intelligent diagnostic assistant for nuclear power plants using explainable artificial intelligence of GRU-AE, LightGBM and SHAP. *Nucl Eng Technol*, 54(4), 1271-1287.
- Patra, B. G., Sharma, M. M., Vekaria, V., Adekkanattu, P., Patterson, O. V., & Glicksberg, B. (2021). Extracting social determinants of health from electronic health records using natural language processing: a systematic review. *J Am Med Inform Assoc*, 28(12), 2716-2727.

- Pavlou, M., Ambler, G., Seaman, S., De Iorio, M., & Omar, R. Z. (2016). Review and evaluation of penalised regression methods for risk prediction in low-dimensional data with few events. *Stat Med*, 35(7), 1159-1177.
- Petch, J., Di, S., & Nelson, W. (2022). Opening the black box: the promise and limitations of explainable machine learning in cardiology. *Can J Cardiol*, 38(2), 204-213.
- Pfohl, S. R., Foryciarz, A., & Shah, N. H. (2021). An empirical characterization of fair machine learning for clinical risk prediction. *J Biomed Inform*, 113, 103621.
- Pirracchio, R., Petersen, M. L., & van der Laan, M. (2015). Improving propensity score estimators' robustness to model misspecification using super learner. *Am J Epidemiol*, 181(2), 108-119.
- Pittman, P. (2010). Health Services Research in 2020: data and methods needs for the future. *Health Serv Res*, 45(5 Pt 2), 1431.
- Porto, B. M., & Fogliatto, F. S. (2024). Enhanced forecasting of emergency department patient arrivals using feature engineering approach and machine learning. *BMC Med Inform Decis Mak*, 24(1), 377.
- Saini, S. S. (2025). Federated Learning for Privacy-Preserving Healthcare AI Models. *Int J Unified Res Dev (IJURD)*, 1(1), 1-5.
- Salerno, S., & Li, Y. (2023). High-Dimensional Survival Analysis: Methods and Applications. *Annu Rev Stat Appl*, 10(1), 25-49.
- Sanchez, P., Voisey, J. P., Xia, T., Watson, H. I., O'Neil, A. Q., & Tsaftaris, S. A. (2022). Causal machine learning for healthcare and precision medicine. *R Soc Open Sci*, 9(8), 220450.
- Sanchez-Morillo, D., Fernandez-Granero, M. A., & A, L. (2015). Detecting COPD exacerbations early using daily telemonitoring of symptoms and k-means clustering: a pilot study. *Med Biol Eng Comput*, 53(5), 441-451.
- Sarijaloo, F., Park, J., Zhong, X., & Wokhlu, A. (2021). Predicting 90 day acute heart failure readmission and death using machine learning-supported decision analysis. *Clin Cardiol*, 44(2), 230-237.
- Sarkies, M. N., Bowles, K. A., Skinner, E. H., Mitchell, D., Haas, R., & Ho, M. (2015). Data collection methods in health services research. *Appl Clin Inform*, 6(1), 96-109.
- Schmier, J. K., & Halpern, M. T. (2004). Patient recall and recall bias of health state and health status. *Expert Rev Pharmacoecon Outcomes Res*, 4(2), 159-163.
- Shafik, W., & Abubakari, M. S. (2026). Regulatory Frameworks: HIPAA, GDPR, and Compliance in Federated Learning. *The Convergence of Federated Learning and Healthcare 5.0 and Beyond: A New Era of Intelligent Health Systems*, 99.
- Sinaga, K. P., & Yang, M. S. (2020). Unsupervised K-means clustering algorithm. *IEEE Access*, 8, 80716-80727.
- Spasic, I., & Nenadic, G. (2020). Clinical text data in machine learning: systematic review. *JMIR Med Inform*, 8(3).
- Strutz, S., Liang, H., Carey, K., Bashiri, F., Jani, P., & Gilbert, E. (2025). Machine Learning for Predicting Critical Events Among Hospitalized Children. *JAMA Netw Open*, 8(5).
- Sun, M., Oliwa, T., Peek, M. E., & Tung, E. L. (2022). Negative Patient Descriptors: Documenting Racial Bias In The Electronic Health Record: Study examines racial bias in the patient descriptors used in the electronic health record. *Health Aff (Millwood)*, 41(2), 203-211.
- Susanto, A. P., Lyell, D., Widyantoro, B., Berkovsky, S., & Magrabi, F. (2023). Effects of machine learning-based clinical decision support systems on decision-making, care delivery, and patient outcomes: a scoping review. *J Am Med Inform Assoc*, 30(12), 2050-2063.
- Talbot, D., Diop, A., Chiu, Y., Sirois, C., & Spieker, A. J. (2025). Guidelines and Best Practices for the Use of Targeted Maximum Likelihood and Machine Learning When Estimating Causal Effects of Exposures on Time-To-Event Outcomes. *Stat Med*, 44(6).
- Talwar, A., Lopez-Olivo, M. A., Huang, Y., Ying, L., & Aparasu, R. R. (2023). Performance of advanced machine learning algorithms over logistic regression in predicting hospital readmissions: A meta-analysis. *Explor Res Clin Soc Pharm*, 11, 100317.
- Teng, Q., Liu, Z., Song, Y., Han, K., & Lu, Y. (2022). A survey on the interpretability of deep learning

- in medical diagnosis. *Multimed Syst*, 28(6), 2335-2355.
- Tennant, P. W., Murray, E. J., Arnold, K. F., Berrie, L., Fox, M. P., & Gadd, S. C. (2021). Use of directed acyclic graphs (DAGs) to identify confounders in applied health research: review and recommendations. *Int J Epidemiol*, 50(2), 620-632.
- Theodorou, B., Xiao, C., & Sun, J. (2023). *Synthesize Extremely High-dimensional Longitudinal Electronic Health Records via Hierarchical Autoregressive Language Model*. <https://doi.org/10.21203/rs.3.rs-2644725/v1>
- Traino, K. A., Sharkey, C. M., Perez, M. N., Bakula, D. M., Roberts, C. M., Chaney, J. M., & Mullins, L. L. (2021). Health care utilization, transition readiness, and quality of life: A latent class analysis. *J Pediatr Psychol*, 46(2), 197-207.
- Vorisek, C. N., Lehne, M., Klopfenstein, S. A. I., Mayer, P. J., Bartschke, A., Haese, T., & Thun, S. (2022). Fast healthcare interoperability resources (FHIR) for interoperability in health research: systematic review. *JMIR Med Inform*, 10(7).
- Vota, F., Pediconi, F., & Liscio, A. (2025). Federated learning in healthcare: Addressing AI challenges and operational realities under the GDPR. *J Data Prot Priv*, 7(3), 235-251.
- Vranas, K. C., Jopling, J. K., Sweeney, T. E., Ramsey, M. C., Milstein, A. S., & Slatore, C. G. (2017). Identifying distinct subgroups of ICU patients: a machine learning approach. *Crit Care Med*, 45(10), 1607-1615.
- Wang, H., Robinson, R. D., Johnson, C., Zenarosa, N. R., Jayswal, R. D., Keithley, J., & Delaney, K. A. (2014). Using the LACE index to predict hospital readmissions in congestive heart failure patients. *BMC Cardiovasc Disord*, 14(1), 97.
- Weissman, G. E., Hubbard, R. A., Ungar, L. H., Harhay, M. O., Greene, C. S., Himes, B. E., & Halpern, S. D. (2018). Inclusion of Unstructured Clinical Text Improves Early Prediction of Death or Prolonged ICU Stay. *Crit Care Med*, 46(7), 1125-1132.
- Weller, B. E., Bowen, N. K., & Faubert, S. J. (2020). Latent class analysis: a guide to best practice. *J Black Psychol*, 46(4), 287-311.
- World Health, O. (2021). *Ethics and governance of artificial intelligence for health: WHO guidance*. World Health Organization.
- Yang, J., Soltan, A. A., Eyre, D. W., Yang, Y., & Clifton, D. A. (2023). An adversarial training framework for mitigating algorithmic biases in clinical machine learning. *NPJ Digit Med*, 6(1), 55.
- Yang, S., Varghese, P., Stephenson, E., Tu, K., & Gronsbell, J. (2023). Machine learning approaches for electronic health records phenotyping: a methodical review. *J Am Med Inform Assoc*, 30(2), 367-381.
- Yu, M. Y., & Son, Y. J. (2024). Machine learning-based 30-day readmission prediction models for patients with heart failure: a systematic review. *Eur J Cardiovasc Nurs*, 23(7), 711-719.
- Zhang, Z., & Hong, Y. (2017). Development of a novel score for the prediction of hospital mortality in patients with severe sepsis: the use of electronic healthcare records with LASSO regression. *Oncotarget*, 8(30), 49637.
- Zhou, M., Thayer, W. M., & Bridges, J. F. (2018). Using latent class analysis to model preference heterogeneity in health: a systematic review. *Pharmacoeconomics*, 36(2), 175-187.

BÖLÜM 9

DİJİTALLEŞEN SAĞLIK SİSTEMLERİ: FARKLI ÜLKE MODELLERİNDE YAPAY ZEKA UYGULAMALARI

Aysel TAMTAMIŞ KURT¹

1.GİRİŞ

Son yıllarda, bilgi ve iletişim teknolojilerindeki hızlı gelişmeler, sağlık sistemlerinin yapısını ve işleyişini önemli ölçüde değiştirmiştir. Özellikle dijitalleşme süreci, sağlık hizmetlerinin sunumu, sağlık verilerinin yönetimi ve klinik karar verme mekanizmalarını yeniden şekillendiren temel bir faktör haline gelmiştir. Bu dönüşüm sürecinde, yapay zeka teknolojileri tanı, tedavi, karar destek mekanizmaları ve sağlık hizmetlerinin yönetimi gibi sağlık sistemlerinin birçok alanında kullanılmaya başlanmıştır (1).

Dijital sağlık sistemleri, sağlık hizmetlerinin daha hızlı, daha erişilebilir ve daha verimli bir şekilde sunulmasını sağlayan teknolojik altyapıları ifade eder. Elektronik sağlık kayıtları, büyük veri analitiği, teletıp uygulamaları ve yapay zeka tabanlı karar destek sistemleri bu dönüşümün ana bileşenleri arasındadır. Sağlık sistemlerinde dijitalleşmenin yaygın olarak benimsenmesi, yalnızca klinik süreçleri değil, aynı zamanda sağlık politikalarının geliştirilmesini ve sağlık sistemlerinin yönetim yapılarını da etkilemektedir (2).

Yapay zeka teknolojileri, özellikle son yıllarda sağlık sektöründe önemli bir araştırma ve uygulama alanı haline gelmiştir. Makine öğrenimi, derin öğrenme ve doğal dil işleme gibi yapay zeka teknikleri sayesinde, büyük miktarda sağlık verisi analiz edilerek daha doğru teşhis süreçleri geliştirilebilir ve klinik karar destek sistemleri güçlendirilebilir (3). Bu gelişmeler, sağlık hizmetlerinin kalitesini iyileştirme potansiyeline sahip olmakla kalmayıp, sağlık sistemlerinin sürdürülebilirliği için de önemli fırsatlar sunmaktadır.

¹ Öğr. Gör. Dr., Ataşehir Adıgüzel Meslek Yüksekokulu, Tıbbi Dokümantasyon ve Sekreterlik Pr., aysel.tamtamis@gmail.com, ORCID iD: 0000-0002-7381-4692

Gelecekte, yapay zeka teknolojilerinin sağlık sistemlerinde daha yaygın olarak kullanılması beklenmektedir. Özellikle yapay zekanın, kişiselleştirilmiş tıp, hastalıkların erken teşhisi ve sağlık hizmetlerinin otomasyonu gibi alanlarda önemli bir rol oynaması öngörülmektedir (1). Bu bağlamda, bu çalışma, farklı sağlık sistemi modelleri çerçevesinde yapay zeka uygulamalarını inceleyerek literatüre kavramsal bir katkı sağlamaktadır. Önerilen model, yapay zekanın entegrasyonunda sağlık sistemlerinin yapısal özelliklerinin belirleyici rolünü vurgulamaktadır. Gelecekteki çalışmaların bu modeli ampirik olarak test etmeye odaklanması önerilmektedir.

KAYNAKLAR

1. Topol E. High-performance medicine: The convergence of human and artificial intelligence. *Nat Med.* 2019;25(1):44–56. doi:10.1038/s41591-018-0300-7
2. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: Past, present and future. *Stroke Vasc Neurol.* 2017;2(4):230–243. doi:10.1136/svn-2017-000101
3. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature.* 2017;542(7639):115–118. doi:10.1038/nature21056
4. Reddy S, Allan S, Coghlan S, Cooper P. A governance model for the application of AI in health care. *J Am Med Inform Assoc.* 2020;27(3):491–497. doi:10.1093/jamia/ocz192
5. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J.* 2019;6(2):94–98. doi:10.7861/futurehosp.6-2-94
6. Lee D, Yoon SN. Application of artificial intelligence-based technologies in the healthcare industry: Opportunities and challenges. *Int J Environ Res Public Health.* 2021;18(1). doi:10.3390/ijerph18010271
7. Keesara S, Jonas A, Schulman K. Covid-19 and health care's digital revolution. *N Engl J Med.* 2020;382(23):e82. doi:10.1056/NEJMp2005835
8. Adler-Milstein J, Huckman RS. The impact of electronic health record use on physician productivity. *Am J Manag Care.* 2013;19(10):SP345–SP352. doi:10.37765/ajmc
9. Shickel B, Tighe PJ, Bihorac A, Rashidi P. Deep learning in electronic health records. *J Biomed Inform.* 2018;83:168–185. doi:10.1016/j.jbi.2018.05.008
10. OECD. Health at a glance 2023: OECD indicators. 2023. doi:10.1787/7a7afb35-en
11. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *N Engl J Med.* 2019;380(14):1347–1358. doi:10.1056/NEJMra1814259
12. Yu KH, Beam AL, Kohane IS. Artificial intelligence in healthcare. *Nat Biomed Eng.* 2018;2(10):719–731. doi:10.1038/s41551-018-0305-z
13. He J, Baxter SL, Xu J, Xu J, Zhou X, Zhang K. The practical implementation of artificial intelligence technologies in medicine. *Nat Med.* 2019;25(1):30–36. doi:10.1038/s41591-018-0307-0
14. Bohr A, Memarzadeh K. The rise of artificial intelligence in healthcare applications. In: *Artificial Intelligence in Healthcare.* 2020. doi:10.1016/B978-0-12-818438-7.00002-2
15. Price WN, Cohen IG. Privacy in the age of medical big data. *Nat Med.* 2019;25(1):37–43. doi:10.1038/s41591-018-0272-7
16. Wahl B, Cossy-Gantner A, Germann S, Schwalbe NR. Artificial intelligence (AI) and global health: How can AI contribute to health in resource-poor settings? *BMJ Glob Health.* 2018;3(4). doi:10.1136/bmjgh-2018-000798
17. T.C. Sağlık Bakanlığı. Türkiye sağlık bilgi sistemleri genel değerlendirme raporu. Ankara: Sağlık Bakanlığı Yayınları; 2022.

Sağlık Yönetiminde Güncel Konular II

18. Yıldırım A, Demir B. Türkiye’de dijital sağlık ve yapay zekâ uygulamalarının gelişimi. Sağlık Yönetimi Dergisi. 2023;5(2):45–60.
19. Mehta N, Pandit A, Shukla S. Transforming healthcare with digital innovation and artificial intelligence. J Med Syst. 2020;44(10). doi:10.1007/s10916-020-01605-1
20. Mesko B. The role of artificial intelligence in precision medicine. Expert Rev Precis Med Drug Dev. 2017;2(5):239–241. doi:10.1080/23808993.2017.1380516

BÖLÜM 10

NETWORK TOKSİKOLOJİSİ ANALİZLERİNDE KULLANILAN BİYOİNFORMATİK ARAÇLAR

Şeyma YAŞAR¹
Neşe BAŞAK TÜRKMEN²

1.GİRİŞ

Günümüzde çevresel ve endüstriyel kimyasallara maruziyet, insan sağlığı açısından giderek artan bir endişe kaynağı hâline gelmiştir. Modern yaşamın vazgeçilmez bir parçası hâline gelen plastikler, gıda ambalajları, kozmetik ürünler, temizlik maddeleri ve çeşitli endüstriyel bileşikler; solunum, oral alım ve dermal temas gibi farklı maruziyet yolları aracılığıyla organizmaya girmekte ve çok sayıda biyolojik sistemi eş zamanlı olarak etkileyebilmektedir (Vanderberg 2022). Bu maruziyetlerin önemli bir kısmı düşük dozlarda ancak uzun süreli ve kronik nitelikte gerçekleşmekte; doğrusal olmayan ve/veya non-monotonik doz-yanıt paternleri gibi olgular, toksik etkilerin klasik yaklaşımlarla değerlendirilmesini güçleştirebilmektedir (Trasende et al., 2015; Ahn et al 2023). Geleneksel toksikoloji yaklaşımları, toksisiteyi çoğunlukla tek bir moleküler hedef veya izole bir biyokimyasal mekanizma üzerinden açıklamayı amaçlamış ve doz-yanıt ilişkisini temel alan indirgemeci bir bakış açısını benimsemiştir (Redelmeier et al.,2023). Ancak biyolojik sistemlerin dinamik, adaptif ve çok katmanlı ağ yapısı dikkate alındığında, bu yaklaşımın özellikle kronik maruziyetler, düşük doz etkileri ve birden fazla organ sistemini ilgilendiren toksik yanıtlar söz konusu olduğunda yetersiz kalabildiği bildirilmektedir (Trasande et al., 2015;Shankar et al., 2021). Aynı kimyasal maddenin farklı dokularda, farklı gelişim dönemlerinde veya bireyler arasında değişken toksik profiller sergileyebilmesi, toksik etkilerin sistem düzeyinde ele alınması gerektiğini açık biçimde ortaya koymaktadır (Zitnik et al., 2018). Bu

¹ Doç. Dr., İnönü Üniversitesi, Tıp Fakültesi Biyoistatistik ve Tıp Bilişimi AD., seyma.yasar@inonu.edu.tr, ORCID iD:0000-0003-1300-3393

² Doç. Dr., İnönü Üniversitesi, Eczacılık Fakültesi, Farmasötik Toksikoloji AD., nese.basak@inonu.edu.tr, ORCID iD:0000-0001-5566-8321

Gelecekte network toksikolojisinin yapay zekâ ve makine öğrenmesi yöntemleriyle entegrasyonu, toksisite öngörüsünde önemli ilerlemeler sağlayabilecek bir yönelim olarak görülmektedir (Kim et al., 2025). Çoklu-omik verilerin birlikte değerlendirilmesi ve ağ temelli çıkarım yöntemlerinin güçlenmesi, toksik etkilerin biyolojik ağlar üzerindeki yansımalarının daha ayrıntılı biçimde modellenmesine olanak tanıyacaktır (Zhang et al., 2024). Ayrıca bu yaklaşımın, hayvan deneylerini azaltma hedefiyle uyumlu olarak daha hızlı ve maliyet etkin alternatif değerlendirme stratejilerine katkı sunması beklenmektedir (Gore et al., 2015). Sonuç olarak network toksikolojisi, toksik etkilerin biyolojik sistemler üzerindeki sonuçlarını daha bütüncül ve mekanistik bir çerçevede değerlendirmeye imkân veren yenilikçi bir yaklaşımdır.

KAYNAKLAR

1. Vandenberg, L. N. (2022). Low dose effects and nonmonotonic dose responses for endocrine disruptors. In *Endocrine disruption and human health* (2nd ed.). Elsevier.
2. Trasande, L., Zoeller, R. T., Hass, U., Kortenkamp, A., Grandjean, P., Myers, J. P., DiGangi, J., Bellanger, M., Hauser, R., Legler, J., Skakkebaek, N. E., & Heindel, J. J. (2015). Estimating burden and disease costs of exposure to endocrine-disrupting chemicals in the European Union. *Journal of Clinical Endocrinology & Metabolism*, 100(4), 1245-1255
3. Ahn, C. H., Oh, T. J., Min, S. H., & Cho, Y. M. (2023). Endocrinology and metabolism. *Endocrinology and Metabolism*, 38(1), 1-9.
4. Redelmeier, D. A., & Zipursky, J. S. (2023). A dose of reality about dose-response relationships. *Journal of General Internal Medicine*, 38(16), 3604-3609.
5. Shankar, V., Mahboob, S., Al-Ghanim, K. A., Ahmed, Z., Al-Mulhm, N., & Govindarajan, M. (2021). A review on microbial degradation of drinks and infectious diseases: A perspective of human well-being and capabilities. *Journal of King Saud University-Science*, 33(2), 101293.
6. Zitnik, M., Agrawal, M., & Leskovec, J. (2018). Modeling polypharmacy side effects with graph convolutional networks. *Bioinformatics*, 34(13), 1457-1466.
7. Hartung, T., FitzGerald, R. E., Jennings, P., Mirams, G. R., Peitsch, M. C., Rostami-Hodjegan, A., ... & Woodung, M. (2017). Systems toxicology: Real world applications and opportunities. *Chemical Research in Toxicology*, 30(4), 870-882.
8. Barabási, A. L., Gulbahce, N., & Loscalzo, J. (2011). Network medicine: A network-based approach to human disease. *Nature Reviews Genetics*, 12(1), 56-68.
9. Gore, A. C., Chappell, V. A., Fenton, S. E., Flaws, J. A., Nadal, A., Prins, G. S., ... & Zoeller, R. T. (2015). Executive summary to EDC-2: The Endocrine Society's second scientific statement on endocrine-disrupting chemicals. *Endocrine Reviews*, 36(6), 593-602.
10. Zoeller, R. T., Brown, T. R., Doan, L. L., Gore, A. C., Skakkebaek, N. E., Soto, A. M., ... & Vom Saal, F. S. (2012). Endocrine-disrupting chemicals and public health protection: A statement of principles from The Endocrine Society. *Endocrinology*, 153(9), 4097-4110.
11. European Food Safety Authority (EFSA), Alvarez, F., Arena, M., Auteri, D., Binaglia, M., Castoldi, A. F., & Villamar-Bouza, L. (2023). Conclusion on the peer review of the pesticide risk assessment of the active substance sulfur. *EFSA Journal*, 21(3), e07805.
12. Wetherill, Y. B., Akingbemi, B. T., Kanno, J., McLachlan, J. A., Nadal, A., Sonnenschein, C., & Belcher, S. M. (2007). In vitro molecular mechanisms of bisphenol A action. *Reproductive Toxicology*, 24(2), 178-198
13. Rochester, J. R. (2013). Bisphenol A and human health: A review of the literature. *Reproductive Toxicology*, 42, 132-155.

14. Stanojević, M., & Sollner Dolenc, M. (2025). Mechanisms of bisphenol A and its analogs as endocrine disruptors via nuclear receptors and related signaling pathways. *Archives of Toxicology*, 1-21.
15. Zhang, G. H., Liu, H., Liu, M. H., Liu, Y. C., Wang, J. Q., Wang, Y., & Zhang, Y. L. (2024). Network toxicology prediction and molecular docking-based strategy to explore the potential toxicity mechanism of Metformin chlorination byproducts in drinking water. *Combinatorial Chemistry & High Throughput Screening*, 27(1), 101-117.
16. Sturla, S. J., Boobis, A. R., FitzGerald, R. E., Hoeng, J., Kavlock, R. J., Schirmer, K., & Whelan, M. (2014). Systems toxicology: From basic research to risk assessment. *Chemical Research in Toxicology*, 27(3), 314-329.
17. Zhao, X., Zhang, S., Zhang, T., Cao, Y., & Liu, J. (2025). A small-scale data driven and graph neural network based toxicity prediction method of compounds. *Computational Biology and Chemistry*, 117, 108393
18. Zhang, B., & Horvath, S. (2005). A general framework for weighted gene co-expression network analysis. *Statistical Applications in Genetics and Molecular Biology*, 4(1).
19. Jeong, H., Mason, S. P., Barabási, A. L., & Oltvai, Z. N. (2001). Lethality and centrality in protein networks. *Nature*, 411(6833), 41-42.
20. Erciyas, K. (2023). Graph-theoretical analysis of biological networks: A survey. *Computation*, 11(10), 188.
21. Heindel, J. J., Blumberg, B., Cave, M., Machtinger, R., Mantovani, A., Mendez, M. A., & Vom Saal, F. S. (2017). Metabolism disrupting chemicals and metabolic disorders. *Reproductive Toxicology*, 68, 3-33.
22. Diamanti-Kandarakis, E., Bourguignon, J. P., Giudice, L. C., Hauser, R., Prins, G. S., Soto, A. M., & Gore, A. C. (2009). Endocrine-disrupting chemicals: An Endocrine Society scientific statement. *Endocrine Reviews*, 30(4), 293-342.
23. Zoeller, R. T., Bergman, Å., Becher, G., Bjerregaard, P., Bornman, R., Brandt, I., ... & Wood, R. T. (2014). A path forward in the debate over health impacts of endocrine disrupting chemicals. *Environmental Health*, 13(1), 1-18.
24. Tan, J., & Han, D. (2025). Network toxicology and machine learning reveal the toxicological impact of Bisphenol A exposure on osteoarthritis. *Medicine*, 104(44), e45406.
25. Nadal, A., Quesada, I., Tudurí, E., Nogueiras, R., & Alonso-Magdalena, P. (2017). Endocrine-disrupting chemicals and the regulation of energy balance. *Nature Reviews Endocrinology*, 13(9), 536-546.
26. Bousoumah, R., Leso, V., Iavicoli, I., Huuskonen, P., Viegas, S., Porras, S. P., & Scheepers, P. T. (2021). Biomonitoring of occupational exposure to bisphenol A, bisphenol S and bisphenol F: A systematic review. *Science of the Total Environment*, 783, 146905.
27. Mustieles, V., & Fernández, M. F. (2020). Bisphenol A shapes children's brain and behavior: Towards an integrated neurotoxicity assessment including human data. *Environmental Health*, 19(1), 66.
28. Kundakovic, M., & Champagne, F. A. (2011). Epigenetic perspective on the developmental effects of bisphenol A. *Brain, Behavior, and Immunity*, 25(6), 1084-1093.
29. Ashauer, R., O'Connor, I., & Escher, B. I. (2017). Toxic mixtures in time-the sequence makes the poison. *Environmental Science & Technology*, 51(5), 3084-3092
30. Yang, Q., Liu, H., Pang, G., Mo, Y., Zhou, C., Huang, M., & Zhang, J. (2025). Machine learning prediction model combined with network toxicology analysis identifies potential cardiotoxic components and mechanisms among 741 pesticides. *Environment International*, 109860.
31. Judson, R. S., Magpantay, F. M., Chickarmane, V., Haskell, C., Tania, N., Taylor, J., ... & Kavlock, R. J. (2015). Integrated model of chemical perturbations of a biological pathway using 18 in vitro high-throughput screening assays for the estrogen receptor. *Toxicological Sciences*, 148(1), 137-154.
32. Kim, S., Chen, J., Cheng, T., Gindulyte, A., He, J., He, S., & Bolton, E. E. (2025). PubChem 2025 update. *Nucleic Acids Research*, 53(D1), D1516-D1525.

33. Davis, A. P., Wieggers, T. C., Johnson, R. J., Sciaky, D., Wieggers, J., & Mattingly, C. J. (2023). Comparative toxicogenomics database (CTD): Update 2023. *Nucleic Acids Research*, 51(D1), D1257-D1262.
34. Szklarczyk, D., Nastou, K., Koutrouli, M., Kirsch, R., Mehryary, F., Hachilif, R., ... & Von Mering, C. (2025). The STRING database in 2025: Protein networks with directionality of regulation. *Nucleic Acids Research*, 53(D1), D730-D737.
35. Szklarczyk, D., Santos, A., Von Mering, C., Jensen, L. J., Bork, P., & Kuhn, M. (2016). STITCH 5: Augmenting protein-chemical interaction networks with tissue and affinity data. *Nucleic Acids Research*, 44(D1), D380-D384.
36. Pham, T. N. H., Nguyen, T. H., Tam, N. M., Y. Vu, T., Pham, N. T., Huy, N. T., & Li, H. (2022). Improving ligand-ranking of AutoDock Vina by changing the empirical parameters. *Journal of Computational Chemistry*, 43(3), 160-169.
37. Safran, M., Rosen, N., Twik, M., BarShir, R., Stein, T. I., Dahary, D., ... & Lancet, D. (2022). The GeneCards suite. In *Practical guide to life science databases* (pp. 27-56). Springer Nature Singapore.
38. Milacic, M., Beavers, D., Conley, P., Gong, C., Gillespie, M., Griss, J., & D'Eustachio, P. (2024). The Reactome pathway knowledgebase 2024. *Nucleic Acids Research*, 52(D1), D672-D678.