

Sağlık Sektöründe Dijital Dönüşüm ve Veri Analitiği Uygulamaları

Andaç İmak¹

Ceren Ünlükal²

Elifcan Göçmen Polat³

Özet

Sağlık sektöründe dijital dönüşümün hızlanmasıyla birlikte yapay zekâ, büyük veri ve dijital teknolojiler sağlık hizmetlerinin temel bileşenleri haline gelmiştir. Artan veri hacminin işlenmesinde, makine öğrenimi ve derin öğrenme yöntemleri tanı, görüntüleme ve tedavi süreçlerinde yüksek doğruluk ve verimlilik sağlamaktadır. Nöroradyoloji, onkolojik ve kardiyovasküler görüntüleme ile dermatoloji alanlarında yapay zekaya dayalı uygulamalar önemli gelişmeler sunmaktadır. Bunun yanında veri güvenliği, etik sorunlar ve dijital olgunluk eksiklikleri sektörün karşılaştığı başlıca zorluklardır. Sonuç olarak çalışma, sağlık sektöründeki dijital dönüşümün yalnızca teknolojik bir değişim olmadığını, aynı zamanda sağlık hizmeti sunumunda kaliteyi artıran, karar süreçlerini güçlendiren ve tüm paydaşları etkileyen kapsamlı bir dönüşüm olduğunu vurgulamaktadır. Dijital çözümlere dayalı yol haritalarının oluşturulmasının, sağlık sektörünün geleceğine yön verecek önemli bir gereklilik olduğu belirtilmektedir.

- 1 Munzur Üniversitesi, Mühendislik Fakültesi , Elektrik-Elektronik Mühendisliği Bölümü, Tunceli, Türkiye. andacimak@munzur.edu.tr, orcid id: 0000-0002-3654-040X
- 2 Munzur Üniversitesi, Mühendislik Fakültesi , Endüstri Mühendisliği Bölümü, Tunceli, Türkiye. cerenunlukal@munzur.edu.tr, orcid id: 0000-0001-9997-7310
- 3 Munzur Üniversitesi, Mühendislik Fakültesi , Endüstri Mühendisliği Bölümü, Tunceli, Türkiye. elifcangocmen@munzur.edu.tr, orcid id: 0000-0002-0316-281X


1. GİRİŞ

Günümüz dünyasında teknolojik olarak yaşanan yenilikler ve değişim rüzgarları, araştırma-geliştirme (AR-GE) dijitalleşme ve süreklilik bağlamında dönüşüm anlayışları ortaya çıkarmaktadır. İkiz dönüşüm kapsamında yeşil ve dijital dönüşümün en itici güçler arasında yer alması, bu dönüşüm için gerekli teknolojilerin kritikliğini de ortaya koymaktadır. Son yıllarda, AR-GE alanında yaşanan hızlı ilerlemelerle birlikte, veri kavramı da giderek daha fazla önem kazanmıştır. Dijital çağda, her gün milyonlarca hatta milyarlarca veri parçası üretilmektedir. Sağlık sektöründe veri analitiği çalışmaları, geleneksel veri yönetimi araçları ile işlenemeyecek derecede büyük, yüksek hızda oluşturulur ve çeşitli kaynaklardan gelmektedir. Sağlık sektöründe araştırma ve geliştirme çalışmaları büyük veri, hastaların tıbbi geçmişleri, tedavi verileri, laboratuvar sonuçları, görüntüleme testleri ve diğer sağlık kayıtlarını içermektedir. Bu verilerin analizi, hastalıkların daha iyi anlaşılmasına, tedavi yöntemlerinin geliştirilmesine, hastalık öncülü ve tedaviye verilen yanıtların tahmin edilmesine yardımcı olabilmektedir. Çalışma, Ar-Ge'nin mühendislikte kullanımını ve dijital dönüşümü şekillendiren temel teknolojiler olan dijitalleşme, yapay zeka, büyük verinin sağlık sektörüne etkileri, dijital dönüşüm araç ve teknolojilerinin sağlık sektöründeki uygulamalarını sunmaktadır.

1.1. Sağlık Sektöründe Dijital Dönüşüm

Sağlık hizmetleri, her bireyin yaşamında temel bir ihtiyaç olarak kabul edilmektedir ve Maslow' un ihtiyaçlar piramidinde fiziksel varlığın gerçekleştirilmesi için temel bir basamak olarak yer almaktadır. Küresel bir pazar haline gelen sağlık hizmetleri, artık ülkelerin kendi sınırları içinde ele alınabilecek bir boyuttan öteye geçmiştir. Özellikle salgın gibi tüm dünyayı etkileyen süreçlerde, açık iletişim, sağlıkta şeffaflık ve dijitalleşmenin öneminin arttığı görülmektedir. Bu alandaki dijital çözümler, özellikle yapay zeka kullanımı günümüzde önem kazanmaktadır. Yapay zekâ destekli bu dönüşüm, sağlık hizmetlerinde ekonomik etkinlik ve hizmet kalitesi artışı sağlarken yeni yönetsel ve teknik risk alanlarını da beraberinde getirmektedir (Karahüseyinoğlu, F, 2024a). Son dönemlerde sağlık sektöründe yapay zeka teknolojileri önemli bir yer edinmiştir. Bu teknolojiler, büyük veri analizi, makine öğrenimi uygulamaları ve robotlar gibi çeşitli alanlarda kullanılarak sağlık hizmetlerinin iyileştirilmesi ve risklerin ölçülmesi sağlanmaktadır (Hossen ve Karmoker, 2020; Dharani ve Kirupa Krishnan (2021); Koç ve M. Türkoğlu (2023); Türkoğlu (2021); Ali ve ark., 2023). Bu bağlamda yapay zeka teknolojisi, bu verilerin analiz edilmesi ve işlenmesinde önemli bir rol oynamaktadır (Comito ve ark., 2020). Şekil 1'de gösterildiği gibi yapay

zeka tabanlı tasarlanan uzman sistemler için bir çok farklı format üzerinden veri üretilmektedir. Makine öğrenimi algoritmaları, güçlü veri depolama ve işleme kapasiteleriyle desteklenmektedir (Charan ve ark., 2018); (Woo ve ark., 2021). Örneğın, günlük tıbbi verilerin analizi, hasta davranışlarının desenlerinin belirlenmesine ve güvenilir tahminlerin yapılmasına olanak tanır. Bu sayede yapay zeka, hastalara daha etkili tanı ve tedavi yöntemleri önermektedir. Yeni teknolojilerin entegre edildiğı gelişmiş hastaneler, yapay zeka teknolojilerini uygulamalarını daha doğru hale getirmek ve işletme maliyetlerini azaltmak için kullanılmaktadırlar (Zhou ve ark., 2020; Margaret Mary ve ark., 2020). Ayrıca, yapay zeka, sağlık uzmanlarına ve hastalara farklı tedavi seçenekleri hakkında detaylı bilgi sağlayarak bilinçli kararlar almalarına yardımcı olmaktadır (Deng ve ark., 2020). Özellikle öğrenme destekli yapay zeka uygulamalarının hastanın yaralanmasına neden olabilecek hatalara yol açabileceğı, veri mahremiyeti endişeleri, erişim zorlukları ve yapay zekanın etik, yasal ve tıbbi boyutları gibi riskler mevcuttur (Aljaaf ve ark., 2015; Srivastava ve Rossi, 2019; Madanan ve ark., 2021; Dwivedi ve ark., 2021). Ancak, yapay zekanın sağlık sektöründe önemli faydaları da vardır. Örneğın, hastalara sağlık konularında daha fazla kontrol sağlama, kanıta dayalı kararlar almayı kolaylaştırma ve sağlık sorunlarını erken teşhis etme gibi avantajları bulunmaktadır (Jaiman ve Urovi, 2020; Samuel ve ark., 2022). Yapay zeka teknolojileri, karmaşık tıbbi prosedürleri desteklerken tıbbi bakım yönetiminin verimliliğini artırabilir. Ancak, yapay zeka uygulamalarının etik ve yasal hususlarının dikkate alınması önemlidir. Bu nedenle, yapay zekanın sağlık sektöründeki etkili kullanımı için uygun normların oluşturulması gerekmektedir (McGregor ve ark., 2020; Wang ve ark., 2020; Zhou ve ark., 2021). Araştırma sonuçlarına dayanarak, yapay zeka teknolojisinin gelecekteki araştırma ve uygulamalara nasıl katkı sağlayabileceğı de tartışılmaktadır (Shaban-Nejad ve ark., 2021).




Şekil 1. Veriden karar verme süreci

1.2. Yapay zeka (AI) Nedir?


Yapay zeka (AI), bilgisayar yazılımının insanın bilişsel süreçlerini taklit etme yeteneğini ifade eder. Bir yapay sinir ağı (YSA), insan beynine benzer şekilde giriş ve çıkış sinyallerini birbirine bağlayan, kendi içerisinde nöronlar ile bağlı katmanlardan oluşan bir ağıdır (Rosenblatt ve ark., 1958). Makine öğrenimi (ML), bilgisayarların verilerden öğrenme yeteneği olarak tanımlanır. Bu verileri kullanarak karar destek sistemlerinin temeli için modeller oluşturmayı içerir. Makine öğrenimindeki algoritmalar, inceledikleri verilerden öğrenme sağlayarak performanslarını arttırabilmektedir (Kumar ve ark., 2023).

Karmaşık ve belirsiz sistemlerde daha iyi kararlar verebilmek için yapay zeka, tıbbi uygulamaları dönüştürme potansiyeline sahip bir teknoloji olarak tanıtılmıştır (Jiang ve ark., 2017; Kumar ve ark., 2023). Şekil 2’de, yapay zekanın sağlık hizmetlerindeki kullanım sürecinde farklı bileşenler arasındaki etkileşimleri gösteren genel bir akış şemasını göstermektedir. Bu süreç boyunca veriler, yapay zeka modeli ve sürece dahil olan insanlar gibi farklı bileşenler arasında etkileşimler vardır. Örneğin, insanlar tarafından toplanan ve önceden işlenen veriler, bir yapay zeka modelini eğitmek için kullanılabilir ve bu model, sağlık profesyonellerinin tedavi önerilerini bildirmek için kullandıkları tahminleri veya kararları yapmak için kullanılabilir (Kumar ve ark., 2023).



Şekil 2. Sağlık hizmetlerinde yapay zeka süreci (Kumar ve ark., 2023)


Bahiru Legesse Jimma (2023) gerçekleştirdiği çalışmada yaptığı analizler doğrultusunda Şekil 1’de verilen yıllara göre yayın sıklıklarını göstermişlerdir. Anahtar kelime olarak sağlık ve yapay zekayı içeren Şekil 3’ te incelendiğinde ortalama olarak, yıllar arasında sağlıkla ilgili yapay zeka araştırmalarına ilişkin bilimsel makalelerin büyüme oranı %37,88 olmuştur. Toplanan toplam 5019 kaydın 926’sı (%18,45) ile 2020 yılı ilk sırada yer alırken, 850’si (%16,94) ile 2021 yılı takip etmiştir.



Şekil 3. Yıllara göre yayın sayıları

Buna ek olarak yapay zekanın bir alt yapısı olan derin öğrenme, 2012 yılında düzenlenen Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet, Competition 2012), nesne tanımlama alanında Krizhevsky ve Sutskever

Evrişimsel Sinir Ağı (ESA) mimarisi ile bu yarışmayı kazanarak, derin öğrenme bilim dünyasında büyük etki oluşturmuştur (Krizhevsky ve ark., 2012). Bu, yeni modeller ve mimariler dahil olmak üzere alanda önemli ilerlemelerin yanı sıra çok çeşitli görevlerde geliştirilmiş iyi performanslara yol açtı. Alandaki yayınların sayısı önemli ölçüde arttı ve bu da bilim camiasında derin öğrenmeye artan ilgiyi ve önemi göstermektedir. 2001 yılından 2022 yılına kadar yılda “Deep Learning” kelimesiyle ilgili yapılan yayınların sayısı Şekil 4’te gösterilmiştir. Bu veriler ScienceDirect veri tabanından elde edilmiştir ve veri tabanında yapılan arama sadece “Deep Learning” anahtar kelimesiyle sınırlandırılmıştır.



Şekil 4. ScienceDirect veritabanında “Deep Learning” anahtar kelimesini içeren yayın sayısı

Şekil 4 incelendiğinde yapay zekada derin öğrenme yöntemlerinin kullanılması gün geçtikçe katlanarak artmaktadır.


2. Tıbbi Uzmanlık Alanlarında Yapay Zeka: Vaka İncelemeleri

2.1. Nöroradyoloji

Makine öğrenimi ve derin öğrenme gibi teknolojiler, nöroradyoloji alanında giderek artan boyuttaki veri kümelerinin etkin bir şekilde işlenmesini ve analiz edilmesini sağlamaktadır. Özellikle denetimli öğrenme teknikleri ve derin öğrenme algoritmaları, beyin görüntülemesi gibi karmaşık veri setlerinden anlamlı bilgiler çıkarmada büyük öneme sahiptir. Bu teknolojilerin uygulanması, inme gibi ciddi sağlık durumlarının erken teşhisini ve tedavisini kolaylaştırabilir. Örneğin, Yedavalli ve ark. gerçekleştirmiş oldukları çalışmalarında enfarktüs veya kanamaların tespiti, beyin damarlarının segmentasyonu, lezyonların sınıflandırılması ve

büyük damar tıkanıklıklarının tanımlanması gibi alanlarda, Evrişimli Sinir Ağlarının (ESA) kullanımı son derece etkili olmuştur (Yedavalli ve ark., 2021). Günümüzde, nöroradyoloji uzmanları, derin öğrenme tekniklerini kullanarak daha hassas ve doğru tanımlar yapabilmekte ve bu da hastaların tedavi süreçlerini iyileştirmektedir. Araştırmacılar, bu teknolojilerin nöroradyoloji pratiğine önemli katkılar sağladığını göstermektedir (Filippi ve ark., 2021). Yapılan araştırmalar, yapay zekanın tromboliz ve trombektomi ile ilgili kararları destekleme potansiyeline dikkat çekmektedir. Örneğin, Shlobin ve ark., büyük damar tıkanıklıklarını BT görüntüleme ile hassas bir şekilde tespit edebilen bir yapay zeka modeli geliştirmiştir. Bu model, trombektomi müdahalesine uygun hastaları belirlemede yüksek düzeyde hassasiyet ve özgüllük göstermektedir (Shlobin ve ark., 2022). Zhu ve ark., akut iskemik felç geçiren hastalarda tromboliz yanıtlarını tahmin etmek için yapay zeka algoritmalarını kullanmıştır. Ayrıca, klinik verilerle görüntüleme özelliklerini entegre ederek, klinisyenlere en etkili tedavi stratejilerini belirleme konusunda destek sağlamışlardır (Zhu ve ark., 2021). Tümör boyutlarının, formlarının ve beyindeki yerleşimlerinin çeşitliliğinin tespiti önem arz etmektedir. Gethaa ve arkadaşları önerdikleri hibrit optimizasyon modeli ile çok sınıflı beyin tümörlerinin teşhisini gerçekleştirmişlerdir (Geetha ve ark., 2024).

Günümüzde felç teşhisinde BT ve MRI gibi görüntüleme teknikleri kullanılmaktadır. Ancak, bu tekniklerin bazı dezavantajları vardır. Örneğin, BT taramaları zaman alıcıdır ve MRI pahalıdır ve her hastane veya klinikte bulunmamaktadır. Bu nedenle, felç teşhisinde alternatif ve daha erişilebilir yöntemlere ihtiyaç vardır. Bu bağlamda, elektroensefalogram (EEG) sinyalleri felç teşhisi için potansiyel bir alternatif olabilir. EEG, beyin aktivitesini ölçen bir yöntemdir ve hasta dostu bir teşhis aracı olarak kabul edilir. Ancak, EEG sinyallerinin analizi ve felç teşhisi için kullanılması konusunda daha fazla araştırmaya ihtiyaç vardır. Sawan ve arkadaşları derin öğrenme ve meta-sezgisel yaklaşımların birleşimini içeren hibrit bir yöntem önermişlerdir. Bu sayede felç teşhisi için daha hızlı, erişilebilen ve maliyet olarak uygun cevap veren bir çözüm sunabileceği düşünülmektedir. Ancak, bu tekniklerin klinik uygulamada etkinliğini değerlendirmek için daha fazla çalışmaya ihtiyacı bulunmaktadır (Sawan ve ark., 2024).




Şekil 5. Nöroradyolojide makine öğrenimi odaklı uygulamalara genel bakış (Najjar, 2023)

2.2. Onkolojik Görüntüleme

Yapay zeka ve makine öğrenimi teknolojilerindeki hızlı ilerlemeler, kanser görüntüleme alanında büyük ilerlemelere yol açmıştır. Yapay zeka ve derin öğrenme stratejileri, farklı türdeki biyolojik verilerin bir araya getirilmesiyle kanserin teşhisi, hastalığın seyri ve tedavisinde önemli bir rol oynamaktadır (Koh ve ark., 2022; Luchini ve ark., 2021). Bu teknolojiler, kanser görüntüleme alanındaki iş yükünün önemli bir kısmını oluşturan sağlık kuruluşlarında aktif olarak araştırılmakta ve benimsenmektedir (Koh ve ark., 2022). Yapay zeka, meme, akciğer ve prostat kanserlerinin tanısında giderek daha fazla kullanılmaktadır ve klinik uygulamalarda yer almaktadır (Luchini ve ark., 2021). Derin öğrenme modelleri ve CNN'ler, bilgisayarlı tomografi taramalarındaki akciğer nodüllerini sınıflandırabilir ve manyetik rezonans görüntülemeye renal hücreli karsinom alt tiplerini ayırt edebilir (Wang ve ark., 2022; Kowaleski ve ark., 2022).

Yapay zeka algoritmaları, geleneksel olarak zaman alan ve gözlemciler arası değişkenliğe duyarlı ölçümleri otomatikleştirerek, tümör boyutundaki veya metabolik aktivitedeki değişiklikleri objektif ve tutarlı bir şekilde değerlendirebilir (Bhandari ve ark., 2020). Ayrıca, yapay zeka, tıbbi görüntülerin ayrıntılı analizi yoluyla tümör değişikliklerini ölçerek tedaviye yanıtın izlenmesinde önemli bir rol oynar. Bu analizler, hastalık davranışı veya sonuçlarıyla bağlantılı matematiksel özellikleri belirlemek için bilgisayarlar tarafından incelenebilir (Najjar, 2023; Koh ve ark., 2022). Ayrıca, yapay zeka, kanser hastalarının prognozunu ve tedavi yanıtının tahmininde, uzman kişilere etkili bir araç olabileceğini göstermektedir.




Şekil 6. Onkolojik görüntüleme makine öğrenimi uygulamalarına genel bakış (Najjar, 2023)

2.3. Kardiyovasküler Görüntüleme

Yapay zeka, kardiyovasküler görüntülemenin önemli bir alanında büyük bir ilerleme kaydetmiştir. Bu ilerlemeler, kalp hastalıklarının daha erken tespit edilmesi ve daha iyi yönetilmesi için önemli fırsatlar sunmaktadır. Yapay zeka algoritmaları, karmaşık ve çok boyutlu görüntüleme verilerini hızlı ve etkili bir şekilde analiz edebilir. Örneğin, makine öğrenimi modelleri ve ESA'lar, koroner arter kalsifikasyonunu otomatik olarak tespit etme ve sol ventriküler miyokardın otomatik segmentasyonunu gerçekleştirme gibi görevleri başarıyla gerçekleştirebilir. Bu tür analizler, kalp hastalıklarının başlangıç aşamalarının erken teşhisini sağlayarak tedavi sürecini iyileştirebilir ve hastaların yaşamını sürdürülebilirliğini artırabilir. Kalp yapısı koşullarının ötesinde, aort anevrizmaları veya periferik arter hastalığı gibi vasküler anormalliklerin analizinde de etkili olup, erken müdahaleyi kolaylaştırarak potansiyel olarak hasta sonuçlarını iyileştirebilir. ESA'ların, BT görüntülerinden abdominal aort anevrizmalarını değerlendirmede etkili olduğu kanıtlanmıştır. Bu, potansiyel olarak yaşamı tehdit eden durumların tespitinde ve boyutlandırılmasında yüksek doğruluk gösterir. Örneğin, ML algoritmaları, MRP'dan elde edilen perfüzyon verilerini BT'den gelen


koroner anatomi verileriyle birleştirilerek karmaşık 3D kalp modelleri oluşturabilmektedir. Bu sayede, kardiyak iskemi tespitini iyileştirmekle birlikte tedavi planlamasını daha hassas hale getirebilmektedir (Zhou ve ark., 2021; Guo ve ark., 2022; Al'Aref ve ark., 2019).



Şekil 7. Göğüs görüntüleme makine öğrenimi uygulamalarına genel bakış (Najjar, 2023)

2.4. Cilt Hastalığı Tanısı

Araştırmacılar, cilt lezyonlarının tespiti ve teşhisinde uygulanan dermatolojik tedaviler için yapay zeka tabanlı çeşitli yöntemler ile ilerlemeler kaydetmişlerdir. Bu doğru tahmin, lezyonların analiz edilmesinin yanı sıra uzmanlar tarafından hastalıkların teşhis edilmesini de etkilemektedir. Dong ve arkadaşları çalışmalarında, TMAHU-Net olarak adlandırdıkları bir derin öğrenme mimarisi önermişlerdir. Cilt lezyonu bölgelerinin karmaşıklığıyla başa çıkmak için transformatör tabanlı çok dikkatli hibrit model ile belirli oranda iyileştirmeler gerçekleştirmişlerdir (Dong ve ark., 2024). Derin öğrenmenin kullanımıyla deri lezyonu görüntülerinin sınıflandırılması, hastalığın erken aşamalarında teşhis edilmesine yardımcı olduğunu göstermektedir (Chamola ve ark., 2024; Khan ve ark., 2024; Zhang ve ark., 2024; Sharen ve ark., 2024). Şekil 8’de cilt lezyon görüntülerine uygulanan makine öğrenmesine genel bir bakış gösterilmiştir.



Şekil 8. Cilt lezyon görüntülerine uygulanan makine öğrenmesi yöntemlerine genel bir bakış

3. Sonuç ve Tartışma

Sağlık sektöründeki Ar-Ge, sağlık sonuçlarını iyileştirmeyi ve dijital çözümlerin benimsenmesini hızlandırmayı amaçlayan teknolojinin sağlık kuruluşlarının tüm alanlarına entegrasyonunu içerir (Konopik & Blunck, 2023; Moulay, 2023). Bu dönüşüm, artan maliyetler, sağlık uzmanlarının sıkıntısı ve tıbbi ihtiyaçların karmaşıklığı gibi zorlukları ele alma ihtiyacından kaynaklanmaktadır. Sağlık hizmeti sunumunu, hasta merkezliliğini ve maliyet sınırlamayı geliştirmek için dijital teknolojilerin kullanımını kapsar. Bu dönüşümdeki kilit paydaşlar arasında tıbbi tedavi sağlayıcıları, hastalar, yönetim kurumları ve ödeme yapanlar yer almaktadır (Barbieri ve ark., 2023). Hastalar teknoloji destekli bir etki büyümesi yaşarken, sağlayıcılar değer yaratma ve hasta etkileşimi için araçlara giderek daha fazla bağımlı hale geliyor. Sağlıkın dijital belirleyicilerinin ve dijital uçurumun ele alınması, dijital teknolojinin sağlık ve refah için faydalarına adil erişim sağlamak için çok önemlidir. Sağlık bilgi sistemlerinin geleceği, verimliliği ve sonuçları artırmak için yapay zekâ modelleri gibi çeşitli araçları entegre eden modüler mimarilerde yatmaktadır.

Özetle, son zamanlarda bu konuda yapılan çalışmaların artış gösterdiği, literatürdeki değerlendirme yöntemlerinin ve olgunluk ölçme kriterlerinin eksikliklerinin olması sebebiyle yeni modeller ve yöntemler araştırma yoluna gidilmektedir. Çalışmanın önemi, önerilen yöntemlerle sağlık sektörünün dijital dönüşüm yolundaki ihtiyaçlarının tespit edilmesi ve ihtiyaçlara göre kısa ve orta vadeli yol haritalarının hazırlanmasının, diğer sektörler için de yol gösterici olacağı düşüncesidir.

Kaynakça

- Al'Aref, S. J., Anchouche, K., Singh, G., Slomka, P. J., Kolli, K. K., Kumar, A., ... & Min, J. K. (2019). Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging. *European heart journal*, 40(24), 1975-1986.
- Ali, O., Abdelbaki, W., Shrestha, A., Elbasi, E., Alryalat, M. A. A., & Dwivedi, Y. K. (2023). A systematic literature review of artificial intelligence in the healthcare sector: Benefits, challenges, methodologies, and functionalities. *Journal of Innovation & Knowledge*, 8(1), 100333.
- Aljaaf, A. J., Al-Jumeily, D., Hussain, A. J., Fergus, P., Al-Jumaily, M., & Abdel-Aziz, K. (2015, July). Toward an optimal use of artificial intelligence techniques within a clinical decision support system. In *2015 Science and Information Conference (SAI)* (pp. 548-554). IEEE.
- Altındış, S., & Kıran Morkoç, İ. (2018). Sağlık Hizmetlerinde Büyük Veri. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(2), 257-271. <https://doi.org/10.25287/ohuiibf.366227>
- Asiltürk, A., 2021. İşletmelerde dijital dönüşüm yönetiminde nihai hedef: Dijital olgunluk. *Alanya Akademik Bakış Dergisi*, 5, 647-669.
- Aslanova, I. V., Kulichkina, A. I., (2020). Digital maturity: Definition and model. In 2nd International Scientific and Practical Conference "Modern Management Trends and the Digital Economy: from Regional Development to Global Economic Growth"(MTDE 2020) (pp. 443-449). Atlantis Press.
- Barbieri, C., Neri, L., Stuard, S., Martín-guerrero, J. D., & Mari, F. (2023). From electronic health records to clinical management systems: how the digital transformation can support healthcare services. *Clinical Kidney Journal*, 16(11), 1878-1884. <https://doi.org/10.1093/ckj/sfad168>
- Bhandari, A., Koppen, J., & Agzarian, M. (2020). Convolutional neural networks for brain tumour segmentation. *Insights into Imaging*, 11(1), 77.
- Canetta, L., Barni, A., & Montini, E. (2018, June). Development of a digitalization maturity model for the manufacturing sector. In *2018 IEEE international conference on engineering, technology and innovation (ICE/ITMC)* (pp. 1-7). IEEE.
- CapGemini & MIT, (2011). Digital Transformation: A Roadmap For Billion-Dollar Organizations, Research Report. MIT Sloan Management Review.
- Charan, S., Khan, M. J., & Khurshid, K. (2018, March). Breast cancer detection in mammograms using convolutional neural network. In *2018 international conference on computing, mathematics and engineering technologies (iCoMET)* (pp. 1-5). IEEE.
- Cisco. (B.T.). 2022 Cisco Global Digital Readiness Index.

- Comito, C., Falcone, D., & Forestiero, A. (2020, December). Current trends and practices in smart health monitoring and clinical decision support. In *2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)* (pp. 2577-2584). IEEE.
- Çelik, K., & Özkan, A. (2017). Eklemleri imalat yöntemleri ile üretim ve onarım uygulamaları. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 5(1), 107-121.
- Chamola, V. (2024). A novel end-to-end deep convolutional neural network based skin lesion classification framework.
- De Carolis, A., Macchi, M., Negri, E., & Terzi, S. (2017). A maturity model for assessing the digital readiness of manufacturing companies. In *Advances in Production Management Systems. The Path to Intelligent, Collaborative and Sustainable Manufacturing: IFIP WG 5.7 International Conference, APMS 2017, Hamburg, Germany, September 3-7, 2017, Proceedings, Part I* (pp. 13-20). Springer International Publishing.
- Deng, Y., Sun, Y., Zhu, Y., Xu, Y., Yang, Q., Zhang, S., ... & Yuan, K. (2019). A new framework to reduce doctor's workload for medical image annotation. *IEEE Access*, 7, 107097-107104.
- Dharani, N. (2021, April). ANN based COVID-19 prediction and symptoms relevance survey and analysis. In *2021 5th international conference on computing methodologies and communication (ICCMC)* (pp. 1805-1808). IEEE.
- Dong, Z., Li, J., & Hua, Z. (2024). Transformer-based multi-attention hybrid networks for skin lesion segmentation. *Expert Systems with Applications*, 244, 123016.
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., ... & Williams, M. D. (2021). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International journal of information management*, 57, 101994.
- Geetha, M., Srinadh, V., Janet, J., & Sumathi, S. (2024). Hybrid archimedes sine cosine optimization enabled deep learning for multilevel brain tumor classification using mri images. *Biomedical Signal Processing and Control*, 87, 105419.
- Gökalp, E., Sener, U., 2017. Development of an assessment model for industry 4.0: industry 4.0-mm. International Conference on Software Process Improvement and Capability Determination, 770, 128-142. DOI: 10.1007/978-3-319-67383-7_10.
- Guo, F., Ng, M., Roifman, I., & Wright, G. (2022). Cardiac Magnetic Resonance Left Ventricle Segmentation and Function Evaluation Using a Trained Deep-Learning Model. *Applied Sciences*, 12(5), 2627.

- Hossen, M. S., & Karmoker, D. (2020, December). Predicting the probability of Covid-19 recovered in south Asian countries based on healthy diet pattern using a machine learning approach. In *2020 2nd International Conference on Sustainable Technologies for Industry 4.0 (STI)* (pp. 1-6). IEEE.
- İzmir Kalkınma Ajansı., 2020. Dijital Dönüşüm Olgunluk Düzeyi Belirleme Aracı Geliştirilmesi Çalışması, Yönetici Özeti. 22 Mart 2022.
- Jaiman, V., & Urovi, V. (2020). A consent model for blockchain-based health data sharing platforms. *IEEE access*, 8, 143734-143745.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., ... & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*, 2(4).
- Jimma, B. L. (2023). Artificial intelligence in healthcare: A bibliometric analysis. *Telematics and Informatics Reports*, 9, 100041.
- Johnson, K. W., Torres Soto, J., Glicksberg, B. S., Shameer, K., Miotto, R., Ali, M., ... & Dudley, J. T. (2018). Artificial intelligence in cardiology. *Journal of the American College of Cardiology*, 71(23), 2668-2679.
- Karahüseyinoğlu, F. (2024a). Artificial intelligence in healthcare: Economic efficiency and digital transformation. Hattusas 1st International Conference on Social Sciences.
- Khan, M. A., Muhammad, K., Sharif, M., Akram, T., & Kadry, S. (2024). Intelligent fusion-assisted skin lesion localization and classification for smart healthcare. *Neural Computing and Applications*, 36(1), 37-52.
- Koh, D. M., Papanikolaou, N., Bick, U., Illing, R., Kahn Jr, C. E., Kalpathi-Cramer, J., ... & Prior, F. (2022). Artificial intelligence and machine learning in cancer imaging. *Communications Medicine*, 2(1), 133.
- Koç, E., & Türkoglu, M. (2022). Forecasting of medical equipment demand and outbreak spreading based on deep long short-term memory network: the COVID-19 pandemic in Turkey. *Signal, image and video processing*, 1-9.
- Konopik, J., & Blunck, D. (2023). Development of an Evidence-Based Conceptual Model of the Health Care Sector Under Digital Transformation: Integrative Review. *Journal of Medical Internet Research*, 25, e41512. <https://doi.org/10.2196/41512>
- Kowalewski, K. F., Egen, L., Fischetti, C. E., Puliatti, S., Juan, G. R., Taratkin, M., ... & Cacciamani, G. (2022). Artificial intelligence for renal cancer: From imaging to histology and beyond. *Asian Journal of Urology*, 9(3), 243-252.
- Kumar, P., Chauhan, S., & Awasthi, L. K. (2023). Artificial intelligence in healthcare: review, ethics, trust challenges & future research directions. *Engineering Applications of Artificial Intelligence*, 120, 105894.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Leyh, C., Bley, K., Schäffer, T., & Forstenhäusler, S. (2016, September). SIMMI 4.0-a maturity model for classifying the enterprise-wide it and software landscape focusing on Industry 4.0. In *2016 federated conference on computer science and information systems (fedcsis)* (pp. 1297-1302). IEEE.
- Luchini, C., Pea, A., & Scarpa, A. (2022). Artificial intelligence in oncology: current applications and future perspectives. *British Journal of Cancer*, 126(1), 4-9.
- Madanan, M., Zulkefli, N. A. M., & Velayudhan, N. C. (2021, January). Designing a hybrid artificial intelligent clinical decision support system using artificial neural network and artificial Bee Colony for predicting heart failure rate. In *2021 International Conference on Computer Communication and Informatics (ICCCI)* (pp. 1-7). IEEE.
- Mary, T. M., Ramanathan, G., Sangamithra, A., & Soumya, K. (2020). Design and enactment of heart attack deduction using IOT measuring device. In *Journal of Physics: Conference Series* (Vol. 1427, No. 1, p. 012014). IOP Publishing.
- McGregor, C., Inibhunu, C., Glass, J., Doyle, I., Gates, A., Madill, J., & Pugh, J. E. (2020, July). Health analytics as a service with artemis cloud: Service availability. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 5644-5648). IEEE.
- Moulay, B. (2023). Digital Innovation in Healthcare. In A. C. Bouarar, K. Mouloudj, & D. M. Asanza (Eds.), *Integrating Digital Health Strategies for Effective Administration* (p. 19). IGI Global. <https://doi.org/10.4018/978-1-6684-8337-4.ch001>
- Najjar, R. (2023). Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*, 13(17), 2760.
- Planing, P., Pfoertsch, W., & AG, D. (2016). The digital business transformation paths from manufacturer to digital ecosystem provider-analyzing the strategic options of large corporations towards digitalization. *Summer Internet Proceedings*, 18(2), 66-70.
- Rockwell Automation., (2014). The Connected Enterprise Maturity Model.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rossmann, A., 2018. Digital Maturity: Conceptualization And Measurement Model. Thirty Ninth International Conference on Information Systems, San Francisco.

- Schumacher, A., Erol, S., Sihni, W., 2016. A maturity model for assessing Industry 4.0 readiness and maturity of manufacturing enterprises. *Procedia Cirp*, 52, 161-166.
- Samuel, J., Kashyap, R., Samuel, Y., & Pelaez, A. (2022). Adaptive cognitive fit: Artificial intelligence augmented management of information facets and representations. *International journal of information management*, 65, 102505.
- Sawan, A., Awad, M., Qasrawi, R., & Sowan, M. (2024). Hybrid deep learning and metaheuristic model based stroke diagnosis system using electroencephalogram (EEG). *Biomedical Signal Processing and Control*, 87, 105454.
- Shaban-Nejad, A., Michalowski, M., Brownstein, J. S., & Buckeridge, D. L. (2021). Guest editorial explainable AI: towards fairness, accountability, transparency and trust in healthcare. *IEEE Journal of Biomedical and Health Informatics*, 25(7), 2374-2375.
- Sharen, H., Jawahar, M., Anbarasi, L. J., Ravi, V., Alghamdi, N. S., & Suliman, W. (2024). FDUM-Net: An enhanced FPN and U-Net architecture for skin lesion segmentation. *Biomedical Signal Processing and Control*, 91, 106037.
- Shlobin, N. A., Baig, A. A., Waqas, M., Patel, T. R., Dossani, R. H., Wilson, M., ... & Levy, E. I. (2022). Artificial intelligence for large-vessel occlusion stroke: a systematic review. *World neurosurgery*, 159, 207-220.
- Srivastava, B., & Rossi, F. (2019). Rating AI systems for bias to promote trustworthy applications. *IBM Journal of Research and Development*, 63(4/5), 5-1.
- Soun, J. E., Chow, D. S., Nagamine, M., Takhtawala, R. S., Filippi, C. G., Yu, W., & Chang, P. D. (2021). Artificial intelligence and acute stroke imaging. *American Journal of Neuroradiology*, 42(1), 2-11.
- Turkoglu, M. (2021). COVIDetectionNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence*, 51(3), 1213-1226.
- Weber, C., Königsberger, J., Kassner, L., & Mitschang, B. (2017). M2DDM—a maturity model for data-driven manufacturing. *Procedia Cirp*, 63, 173-178.
- Woo, Y., Andres, P. T. C., Jeong, H., & Shin, C. (2021, April). Classification of diabetic walking through machine learning: Survey targeting senior citizens. In *2021 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* (pp. 435-437). IEEE.
- Wang, S., Bonomi, L., Dai, W., Chen, F., Cheung, C., Bloss, C. S., ... & Jiang, X. (2016). Big data privacy in biomedical research. *IEEE Transactions on big Data*, 6(2), 296-308.

- Wang, H., Zhu, H., & Ding, L. (2022). Accurate classification of lung nodules on CT images using the TransUnet. *Frontiers in Public Health*, 10, 1060798.
- Westerman, G., Bonnet, D., ve McAfee, A. 2014. Leading Digital: Turning Technology into Business Transformation. Harvard Business Review Press.
- Yedavalli, V. S., Tong, E., Martin, D., Yeom, K. W., & Forkert, N. D. (2021). Artificial intelligence in stroke imaging: current and future perspectives. *Clinical imaging*, 69, 246-254.
- Zhang, D., Li, A., Wu, W., Yu, L., Kang, X., & Huo, X. (2024). CR-Conformer: a fusion network for clinical skin lesion classification. *Medical & Biological Engineering & Computing*, 62(1), 85-94.
- Zhou, L., Li, Z., Zhou, J., Li, H., Chen, Y., Huang, Y., ... & Gao, X. (2020). A rapid, accurate and machine-agnostic segmentation and quantification method for CT-based COVID-19 diagnosis. *IEEE transactions on medical imaging*, 39(8), 2638-2652.
- Zhou, R., Zhang, X., Wang, X., Yang, G., Guizani, N., & Du, X. (2020). Efficient and traceable patient health data search system for hospital management in smart cities. *IEEE Internet of Things Journal*, 8(8), 6425-6436
- Zhou, J., Du, M., Chang, S., & Chen, Z. (2021). Artificial intelligence in echocardiography: detection, functional evaluation, and disease diagnosis. *Cardiovascular ultrasound*, 19, 1-11.
- Zhu, B., Zhao, J., Cao, M., Du, W., Yang, L., Su, M., ... & Zhao, Z. (2022). Predicting 1-hour thrombolysis effect of r-tPA in Patients with acute ischemic stroke using machine learning algorithm. *Frontiers in Pharmacology*, 12, 759782.