

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

26-27 Nisan 2024
Kütahya

KONGRE KİTABI

EDİTÖRLER

Prof. Dr. Ahmet Tekin
Dr. Öğr. Üyesi Can Özlü
Dr. Öğr. Üyesi Aycan Acet
Dr. Öğr. Üyesi Sema Üstündağ
Dr. Öğr. Üyesi Gamze Ünver
Dr. Öğr. Üyesi Nilüfer Köylüoğlu
Dr. Öğr. Üyesi Ahmet Güven



1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

26-27 Nisan 2024, Kütahya

KONGRE KİTABI

EDİTÖRLER

Prof. Dr. Ahmet Tekin
Dr. Öğr. Üyesi Can Özlü
Dr. Öğr. Üyesi Aycan Acet
Dr. Öğr. Üyesi Sema Üstündağ
Dr. Öğr. Üyesi Gamze Ünver
Dr. Öğr. Üyesi Nilüfer Köylüoğlu
Dr. Öğr. Üyesi Ahmet Güven

E-ISBN: 978-605-7016-2-6

Kütahya Sağlık Bilimleri Üniversitesi Yayınları - 3



ÖNSÖZ

Tıp ve teknoloji dünyasının kesişim noktasında buluşan Kütahya İnovatif Tıp ve Yapay Zekâ Kongresinde, sağlık hizmetlerinde teknolojik yenilikleri tanıma şansı bulduk. Bu kongrede, yapay zekanın sağlık sektörüne sunduğu katkılar ve dönüştürücü rolü bilimsel tartışmalarımızın merkezinde yer aldı.

Sağlık hizmetlerinin verimliliğini artırma ve hasta odaklı yaklaşımları geliştirme konusunda yapay zekâ büyük potansiyel barındırıyor. Kütahya Sağlık Bilimleri Üniversitesi olarak sağlık alanındaki gelişmeleri yakından takip ediyor ve bu doğrultuda da bilimsel faaliyetler düzenlenmeye çalışıyoruz.

Bu kongrede emeği geçen başta akademisyenlerimiz olmak üzere, sağlıkçılarımız, teknoloji uzmanları ve öğrencilerimize teşekkür ederim.

Prof. Dr. Ahmet TEKİN
Rektör





1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

KONGRE KÜNYESİ

Kongre Adı

1.İnovatif Tıp Teknolojileri ve
Yapay Zeka Kongresi

Kongre Tarihi

26-27 Nisan 2024

Kongre Başkanı

Dr. Öğr. Üyesi Can ÖZLÜ

Kongre Yeri

Kütahya Sağlık Bilimleri
Üniversitesi
Tıp Fakültesi
Sağlık Bilimleri Fakültesi

Kongre Öğrenci Kurulu Başkanları

Serasu ÇAMKAYA
Elif KAPLAN
Duygu YILMAZ

Editör

Prof.Dr. Ahmet Tekin
Dr.Öğr.Üyesi Can Özlü
Dr.Öğr.Üyesi Aycan Acet
Dr.Öğr.Üyesi Sema Üstündağ
Dr.Öğr.Üyesi Gamze Ünver
Dr.Öğr.Üyesi Nilüfer Köylüoğlu
Dr.Öğr.Üyesi Ahmet Güven

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

Kongre Başkanı

Dr. Öğr. Üyesi Can ÖZLÜ

Kongre Başkan Yardımcıları

Dr. Öğr. Üyesi Sema ÜSTÜNDAĞ

Dr. Öğr. Üyesi Gamze ÜNVER

Dr. Öğr. Üyesi Aycan ACET

Dr. Öğr. Üyesi Nilüfer KÖYLÜOĞLU

Dr. Öğr. Üyesi Ahmet GÜVEN

Dr. Öğr. Üyesi Ayşegül DURMAZ

Düzenleme Kurulu

Prof. Dr. Emel KOÇAK

Prof. Dr. Hasan Emre AYDIN

Prof. Dr. Orhan ÖZATİK

Prof. Dr. Sezgin ZEREN

Prof. Dr. Hamdi Melih SARAOĞLU

Prof. Dr. Faik YAYLAK

Prof. Dr. Yılmaz KAYA

Prof. Dr. Öznur AK

Prof. Dr. Yasemin TAŞÇI

Prof. Dr. Sultan GÜÇLÜ

Doç. Dr. Fatma BAŞAR

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

Düzenleme Kurulu

Doç.Dr.Çiğdem ÖKTEN

Dr. Öğr.Üyesi Ayşegül SAVCI

Dr. Öğr.Üyesi Kevser KARACABAY

Dr. Öğr.Üyesi Betül YAVUZ

Dr. Öğr.Üyesi Nigâr ÇELİK

Doç Dr Mehmet Fatih EKİCİ

Dr Öğretim Üyesi Can ÖZLÜ

Dr Öğretim Üyesi Mustafa ERSOY

Doç. Dr. Nihal Yurteri

Doç Dr. Yasemin ÖZATİK

Doç Dr Aysun ÖZLÜ

Dr Öğretim Üyesi Nilüfer KÖYLUOĞLU

Dr Öğretim Üyesi Aycan ACET

Dr Öğretim Üyesi Ahmet GÜVEN

Dr Öğretim Üyesi Gamze ÜNVER

Dr Öğretim Üyesi Sema ÜSTÜNDAĞ

Dr. Öğretim Üyesi Ayşegül DURMAZ

Dr Öğretim Üyesi Elif Tuğçe ÇİTİL

Uz Dr Cumali YALÇIN

Doç Dr Semra ULUSOY

Dr Öğretim Üyesi Ulya KESKİN

Dr Öğretim Üyesi Emre GÜNGÖR

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

Düzenleme Kurulu

Dr. Öğr. Üyesi Ayşegül UNUTKAN
Dr. Öğr. Üyesi Hülya TOSUN
Dr. Öğr. Üyesi. Feyza AKTAŞ REYHAN
Dr. Öğr. Üyesi Ayfer ESER

Bilim Kurulu

Prof. Dr. Azer Ahundov
Prof.Dr.Alpaslan Duysak
Prof Dr Ejaz KHAN
Prof Dr Waseem F ALTameemi
Doç Dr Aysun ÖZLÜ
Doç Dr Yılmaz Kaya
Doç.Dr. Fatma BAŞAR
Doç.Dr. Çiğdem ÖKTEN
Dr. Öğr.Üyesi Ayşegül SAVCI
Dr. Öğr.Üyesi Kevser KARACABAY
Dr. Öğr.Üyesi Betül YAVUZ
Dr. Öğr.Üyesi Nigâr ÇELİK
Doç Dr. Nagyne Habil Hajnal Eva
Assistant Prof Gaye Ediboglu Bartos
Dr Türkay KART
Dr Pervane Rustemova
Dr Günel Qemberova

1. İNOVATİFTİP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

Bilim Kurulu

Dr. Fahad Umer

Dr Öğretim Üyesi Aycan ACET

Dr Öğretim Üyesi Ahmet GÜVEN

Dr. Öğretim Üyesi Ayşegül DURMAZ

Dr Öğretim Üyesi Elif Tuğçe ÇİTİL

Dr. Öğr. Üyesi Yeşim Tunç

Dr. Öğr. Üyesi Nikki Hafezi

Dr.Öğr.Üyesi Muhammed Hanif

Dr.Öğr.Üyesi Mohamed Brahim

Dr.Öğr. Üyesi Melek Önen

Dr.Luiz Arthur

Dr.Saida Khanmamedova

Dr.Fahad umer

Dr.Nikki Hafezi

Dr. Carlos Manuel Llanos Albornoz

Dr.Waseem Altameemi

Kongre Sekreteryası

Öğr.Gör.Dr. Necibe DAĞCAN

Öğr.Gör. Burcu NAL

Arş. Gör. Feride ÇEVİK

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

ÖĞRENCİ DÜZENLEME KURULU

Kongre Başkanları

Duygu YILMAZ
Serasu ÇAMKAYA
Elif KAPLAN

Genel Sekreteryası

Seçil ALTUNBAŞ
Elif YILDIZ
Enes KAY

İletişim Ekibi

Zeynep İrem ALTAŞ
Cennet Şewal DEMİR
Seçil ALTUNBAŞ
Enes KAY

Basın Yayın Ekibi

Serasu ÇAMKAYA
Kürşat BEDİR
Ahmet Übeyde MUTLU
Muharrem Eren DENİZ
Umut Yusuf ÇINAR
Tuba ÖZMARKUPÇU
Eda MERAL
Dilara KALKAN

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

Bilimsel Program Ekibi

Elif KAPLAN

Serasu ÇAMKAYA

Duygu YILMAZ

Furkan CAN

Kürşat BEDİR

Enes KAY

Rüveyda DEMİRCİ

Seçil ALTUNBAŞ

Tuba ÖZMARKUPÇU

Zeynep İrem ALTAŞ

Elif YILDIZ

Şeyma ŞAHİN

Seren KURU

Esra AKGÖL

Aslı KARAOĞLU

Ahmet Übeyde MUTLU

Muharrem Eren DENİZ

Nur ALHERAKİ

Eda MERAL

Kardelen CAN

Alperen TAŞ

Eslem ALTIN

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

Sosyal Program Ekibi

Elif YILDIZ

Enes KAY

Rüveyda DEMİRCİ

Seçil ALTUNBAŞ

Tuba ÖZMARKUPÇU

Zeynep İrem ALTAŞ

Mali Ekip

Alperen TAŞ

Eda MERAL

Kardelen CAN

Ceyda ALÇİN

Ayşe YILDIZOĞLU

Ramazan Yıldırım KARAMAN

Taha Melih KARAMAN

Ezgi DÜLGER

Barış GÜLEÇ

Aysu KILINÇ

Süha Emre İNAL

Abdurrahman ERGEZER

Melike ACAR

Beytullah ATASOY

Sena KALKAN

KONGRE PROGRAMI

TIP VE MÜHENDİSLİK OTURUMU 26 NİSAN 2024

SALON 1

	KONU	KONUŞMACI	MODERATÖR
08.30-09.00	AÇILIŞ		
09.00-09.20	Müzik Dinletisi		
09.20-09.40	Yapay Güçten Yapay Zekâya	Dr. Öğr. Üyesi M.Ali Gedik	Prof. Dr. Orhan Özatik/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
09.40-10.00	Biyoyazıcılar Konusu	Prof. Dr. Hasan Emre Aydın	Prof. Dr. Orhan Özatik/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
10.00-10.20	Tıkınırcasına Yeme Bozukluğunun Makine Öğrenmesi Yöntemleri Kullanılarak Tahmin Edilmesi	Prof. Dr. Ayşegül Bayramoğlu	Prof. Dr. Orhan Özatik/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
10.20-10.40	Giyilebilir Teknolojiler ve Yapay Zekâ Uygulamaları	Dr. Öğr. Üyesi Hüseyin Coşkun	Prof. Dr. Orhan Özatik/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
10.40-11.00	ARA		
11.00-11.20	Teröpatik Klonlama	Prof. Dr. Orhan Özatik	
11.20-12.00	Google Konuşma	Havzullah Yıldırım	
13.00-13.20	Medikal Görüntü Analizi	Dr. Öğr. Üyesi Ahmet Baştuğ	Dr. Öğr. Üyesi M. Ali Gedik Dr. Öğr. Üyesi Can Özlü
13.20-13.40	Eğitimde Teknoloji ve Birlikteliğin Gücü	KAHVE	
13.40-14.00	Büyük Dil Modelleri (ChatGPT)	Dr. Öğr. Üyesi Ahmet Güven	
14.00-14.20	ARA		
14.20-14.50	Yeni Bir Finansman Modeli "Paya Dayalı Kitle Fonlaması"	Sn. Orhan Mutlu Topal	Dr. Öğr. Üyesi M. Ali Gedik/ Dr. Öğr. Üyesi Can Özlü
14.50-15.10	Elektronik Burun Teknolojsi	Prof.Dr.Melih Saraoğlu	Dr. Öğr. Üyesi M. Ali Gedik/ Dr. Öğr. Üyesi Can Özlü
15.10-15.30	Kanser Türlerine Ait Mikrodizi Gen İfade Verilerinde Makine Öğrenme Yöntemlerinin Uygulanması	Dr. Öğr. Üyesi Özlem Arık	Dr. Öğr. Üyesi M. Ali Gedik/ Dr. Öğr. Üyesi Can Özlü
15.30-15.50	Makine Öğrenmesi Uygulamaları	Dr. Öğr. Üyesi Serel Akyol	Dr. Öğr. Üyesi M. Ali Gedik/ Dr. Öğr. Üyesi Can Özlü
16.10-16.30	International Hybrid Artificial Intelligence Congress	Nikki Hafezi	Dr. Melih Saraoğlu/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
16.30-16.50	Privacy-Preserving AI for Health Care	Melek Önen	Dr. Melih Saraoğlu/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
16.50-17.10	AI in healthcare research	Prof. Dr Ejaz KHAN İslamabad	Dr. Melih Saraoğlu/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu
17.10-17.30	AI and surgical robots	Dr Muhammed Hanif	Dr. Melih Saraoğlu/ Dr. Öğr. Üyesi Nilüfer Köylüoğlu

SALON 2			
	KONU	KONUŐMACI	MODERATÖR
8.30-09.00	AÇILIŐ		
09.00-09.20	Müzik Dinletisi		
09.20-09.40	Sinir sistemi ve Bilgisayarlar Arası İletifim	Dr. Öğr. Üyesi Vedat Kavalcı	Prof. Dr Faik Yaylak/ Doç. Dr. Mehmet Fatih Ekici
09.40-10.00	Sağlıkta Büyük Veri ve Yapay Zeka	Dr. Öğr. Üyesi Zekeriya Katılmış	Prof. Dr Faik Yaylak/ Doç. Dr. Mehmet Fatih Ekici
10.00-10.15	Giyilebilir Teknolojilerin Sağlıkta Yeri	Seçil Altunbaş	Prof. Dr Faik Yaylak/ Doç. Dr. Mehmet Fatih Ekici
10.15-10.30	Yenilikçi Nükleer PİL Teknolojisi ve Kalp Pillerinde Etkisi	Enes Kay	Prof. Dr Faik Yaylak/ Doç. Dr. Mehmet Fatih Ekici
10.30-10.40	Bulaşıcı Hastalıklar Ve Yapay Zeka	Cennet Şevval Demir	Prof. Dr Faik Yaylak/ Doç. Dr. Mehmet Fatih Ekici
10.40-11.00	ARA		
11.00-11.20	Uygulamalarla Yapay Zeka	Prof. Dr. Osman Erođlu	
11.20-11.40	Eđitimde Teknoloji ve Birlikteliđin Gücü	Dr. Öğr. Üyesi Aysun Özlü	
11.40-12.30	GOOGLE	Nusret Özateş	
12.30-13.30	YEMEK		
13.30-13.50	Radyolojik Perspektiften Sağlık Bilimlerinde Yapay Zekâ Uygulamaları	Doç. Dr. Ali Murat Koç	Dr. Öğr. Üyesi Zekeriya Katılmış/ Dr. Öğr. Üyesi Mustafa Ersoy
13.50-14.10	Klinik Karar Destek Sistemleri ve Sağlık Sistemine Etkisi	Doç. Dr. Esra Meltem Koç	Dr. Öğr. Üyesi Zekeriya Katılmış/ Dr. Öğr. Üyesi Mustafa Ersoy
14.20-14.40	Pediatride Yapay Zekâ Kullanım Örnekleri	Prof. Dr. Ayfer Açıkgöz	Dr. Öğr. Üyesi Zekeriya Katılmış/ Dr. Öğr. Üyesi Mustafa Ersoy
14.40-15.00	Sağlık Alanında Yapılan Yapay Zekâ Çalışmalarında Mühendis İşbirliđi	Doç. Dr. Özer Çelik	Dr. Öğr. Üyesi Zekeriya Katılmış/ Dr. Öğr. Üyesi Mustafa Ersoy
15.00-15.20	Pediatride Yapay Zekâ Kullanımı: Avantajlar, Dezavantajlar, İkilimler	Dr. Öğr. Üyesi Deniz Yiđit	Dr. Öğr. Üyesi Zekeriya Katılmış/ Dr. Öğr. Üyesi Mustafa Ersoy
15.20-15.50	Yeni Bir Finansman Modeli "Paya Dayalı Kitle Fonlaması"	Orhan Mutlu Topal	
15.50-16.10	ARA		
16.10-16.30	Görüntü Kaydı Gerektiren Hayvan Davranış DeneYlerinde Veri Analizinde Yapay Zekânın Kullanımı	Dr. Öğr. Üyesi Ulya Keskin	Doç. Dr. Nihal Yurteri
16.30-16.50	Çekişmeli Üretici Ağlar	Dr. Öğr. Üyesi Emre Güngör	Doç. Dr. Nihal Yurteri
16.50-17.10	Yükseltilmiş Artı Labirent Açık Alan Ve Morris'in Su Labirent	Melkan Kağan Kara	Doç. Dr. Nihal Yurteri
17.10-17.30	Large Language Models ve İş Gücüne Etkisi	Barış Güleç & Semih Ocaklı	Doç. Dr. Nihal Yurteri

TIP VE MÜHENDİSLİK OTURUMU
27 NİSAN 2024

SALON 1

	KONU	KONUŞMACI	MODERATÖR
08.30-09.00	AÇILIŞ		
09.00-09.20	Endoskopi Görüntülerinde Yapay Zekâ Uygulamaları	Prof. Dr. Eyyüp Gülbandılar	Prof. Dr. Orhan Özatik/ Dr.Öğr. Üyesi Nilüfer Köylüoğlu
09.20-09.40	Üretken Ağlarla Medikal Görüntülerin Çoğaltılması	Dr. Öğr. Üyesi Yahya Doğan	Prof. Dr. Orhan Özatik/ Dr.Öğr. Üyesi Nilüfer Köylüoğlu
09.40-10.00	Fiziksel Tıp ve Rehabilitasyonda Sanal Gerçeklik	Doç. Dr. Aysun Özlü	Prof. Dr. Orhan Özatik/ Dr.Öğr. Üyesi Nilüfer Köylüoğlu
10.00-10.10	Organ Naklinde Yapay Zekâ	Elif Kaplan	Prof. Dr. Orhan Özatik/ Dr.Öğr. Üyesi Nilüfer Köylüoğlu
10.10-10.20	Kişiselleştirilmiş Tıp ve Yapay Zekâ	Serasu Çamkaya	
10.20-10.40	KBB Perspektifinden Endoskopun Gelişimi ve Geleceği	Dr. Sami Engin Muz	Prof. Dr. Orhan Özatik/ Dr.Öğr. Üyesi Nilüfer Köylüoğlu
11.00-11.15	Beyin bilgisayar arayüzü ile medikal uygulamalar ve Yapay Zekânın konumu	Duygu Yılmaz	
11.15-12.00	AI Basic Concepts and Use Cases	Dr. Senem Tanberk - Huawei Research and Innovation Manager	
12.00-13.00	YEMEK		
13.30-13.50	Sağlıkta Chatbots ve Yapay Zekâ	Dr. Funda Sicim Keskin	
13.50-14.10	Patent başvuru	Elif Tuğçe Çitil	
14.10-14.30	Dijital sağlıkta girişimcilik	Kaan Nalbant	
14.30-14.50	ARA		
14.50-15.10	Cerrahi Risk Değerlendirilmesinde Yapay Zekâ Uygulamaları	Prof. Dr. Faik Yaylak	Doç. Dr. Aysun Özlü/ Doç. Dr. Yasemin Özatik
15.10-15.30	Dijitalleşme ve Sağlıkta Yapay Zekânın Türkiyedeki Yeri	Proje Geliştirme Dairesi Başkanlığı Nihat Barış Sebik	Doç. Dr. Aysun Özlü/ Doç. Dr. Yasemin Özatik
15.30-15.40	Tedarikte Afet Bölgesi İlaçlarının İletişimi	Furkan Yıldırım	Doç. Dr. Aysun Özlü/ Doç. Dr. Yasemin Özatik
15.30-17.00	WORKSHOP ETKİNLİKLERİ		
17.00-19.00	KONSER		

SALON 2

9.00-09.20	Uygulamalarla Yapay Zekâ	Prof. Dr. Osman Eroğlu	Prof. Dr. Yasemin Taşçı / Uz. Dr. Cumali Yalçın
09.20-09.40	Optimization Algoritmaları ve Sürü Zekâsı	Doç. Dr. Burhanettin Durmuş	Prof. Dr. Yasemin Taşçı / Uz. Dr. Cumali Yalçın
09.40-10.00	Yapay Zekâ İçin Medikal Görüntülerin Hazırlanması	Dr. Öğr. Üyesi Cüneyt Özdemir	Prof. Dr. Yasemin Taşçı / Uz. Dr. Cumali Yalçın
10.00-10.20	İlaç Tedavisinde Yapay Zekâ	Doç. Dr. Yasemin Özatik	Prof. Dr. Yasemin Taşçı / Uz. Dr. Cumali Yalçın
10.20-10.40	Rutin Biyokimya Laboratuvarında Yapay Zekâ Kullanım Alanları	Dr. Öğr. Üyesi Fatmagül Can	Prof. Dr. Yasemin Taşçı / Uz. Dr. Cumali Yalçın
10.40-11.00	ARA		
11.00-11.20	CYTOF Teknolojileri	Dr. Öğr. Üyesi Suna Saygılı	
11.20-11.40	Bir Girişimcilik Fikrin Varsa Bu Konu Tam Sana Göre	Ahmet Özrenk	Dr. Öğr. Üyesi Emre Güngör/ Dr. Ulya Keskin
11.40-11.50	KLL'de Yapay Zekâ	Berrin Korkut	Dr. Öğr. Üyesi Emre Güngör/ Dr. Ulya Keskin
11.50-12.00	Psikiyatrik Bozuklukların Tanısında Ve Psikoterapi Analizinde Yapay Zekâ	Kağan Misci	Dr. Öğr. Üyesi Emre Güngör/ Dr. Ulya Keskin
12.00-13.00	YEMEK		
13.30-14.30	HUAWEI WorkShop	Yalçın Karayıldız - HUAWEI Cloud Engineer	
15.30-17.00	ATÖLYELER		
17.00-19.00	KONSER		

HEMŞİRELİKTE İNOVATİF UYGULAMALAR OTURUMLARI
BİLİMSEL PROGRAMI

26.04.2024

(Germiyan Yerleşkesi Konferans Salonu)

26 Nisan 2024, Cuma/ Salon Germiyan Kampüsü Konferans Salonu

9:00-9:30 Açılış Konuşmaları

9:30-11:00 Konferans 1 (Online)

Oturum Başkanı: Doç. Dr. Çiğdem Ökten

Konu: Sağlık Bakım Uygulamalarında Giyilebilir Teknolojiler

Konuşmacı: Dr. Öğr. Üyesi Remziye Semerci (Koç Üniversitesi)

Konu: Sağlık Profesyonellerinin Eğitiminde Simülasyon Kullanımı:

Copenhagen Academy for Medical Education and Simulation, Danimarka Örneği

Konuşmacı: Öğr. Gör. Büşra Caz (Ankara Medipol Üniversitesi)

Konu: Sağlık bakım uygulamalarında tele-sağlık uygulamalarının incelenmesi

Konuşmacı: Öğr. Gör. Dr. Halil İbrahim Tuna (Selçuk Üniversitesi)

11:00-11:15 Kahve Arası

11:15-12:00 Konferans 2 (Yüz Yüze)

Oturum Başkanları: Doç. Dr. Fatma Başar, Dr. Öğr. Üyesi Nigâr Çelik

Konu: Yara bakımında güncel gelişmeler ve yapay zekâ uygulamaları

Konuşmacı: Dr. Öğr. Üyesi Ayşegül Savcı (KSBU SBF Cerrahi Hastalıklar Hemşireliği Anabilim Dalı Başkanı)

Konu: Hemşirelik eğitiminde teknoloji temelli uygulamalar

Konuşmacı: Öğr. Gör. Hazal Özcan (KSBU SBF Hemşirelikte Öğretim Anabilim Dalı Başkanı)

12:00 - 13:30 Öğle Yemeği

14:00-15:00 SÖZEL BİLDİRİLER (BZ-05)

Oturum Başkanları: Öğr. Gör. Dr. Necibe Dağcan Şahin, Öğr. Gör. Burcu Nal

EBELİK OTURUMU

26 NİSAN 2024

13:35-14:00	Dr. Öğr. Üyesi Elif Tuğçe Çitil	Kütahya Sağlık Bilimleri Üniversitesi Teknoloji Transfer Ofisi Uygulama Ve Araştırma Merkezi Patent Süreçleri
14:00-14:15	Dr. Öğr. Üyesi Elif Tuğçe Çitil	Klinisyen Ve Öğrenci Ebelerin Perspektifinden Ebelik Bakım Süreçlerinde Yapay Zeka
14:15-14:25	Dr. Öğr. Üyesi Hülya Tosun	Uzaktan Ebelik Bakım Uygulamaları
14:25-14:35	Öğr. Gör. Büşra Sayıl	Ebelikte Sanal Gerçeklik Ve 3d Yazıcılar
14:35-14:45	Öğr. Gör. Ebru Ertaş	Ebelerin Obstetri Uygulamalarında Sanal Gerçeklik
14:45-14:55	Arş. Gör. Feride Çevik	Ebelerin Obstetri Uygulamalarında Simülasyon
Oturum 2– Germiyan Yerleşkesi Konferans Salonu (Çevrimiçi)		
15:15-15:45	Prof. Dr. Fatma Deniz Sayiner Eskişehir Osmangazi Üniversitesi	Teknolojik Gelişmelerin Ebelik Mesleğine Yansımaları
15:45-16:15	Prof. Dr. Serap Ejder Apay, Atatürk Üniversitesi	Ebelikte İnovatif Düşünme Ve Patent Başvuru Süreçleri
Sözlü Bildiriler Oturumu – Salon (Bz-05)		
14:00-15:00	Sözlü Bildiriler	Arş. Gör. İmran Ülkü Alev

İçindekiler Tablosu

Proposed Parallel DenseNet Model for Anomaly Detection in Musculoskeletal System - Hand Part X-Ray Images	3
Derin Öğrenme Modelleriyle Kemik Kırıklarının Tespiti	4
Psoriasis Ve Yapay Zeka.....	12
Sağlık Hizmetleri Ve Eğitiminde Yapay Zeka Kullanımı: Büyük Dil Modelleri (Llm) Ve Üretken Çekişmeli Ağ Modelleri (Gan).....	14
Yapay Zeka Ve Melanoma: Klinikte Kullanımı	30
Yapay Zeka Ve Robot Hemşireler	32
Derin Öğrenme Yöntemlerine Ön Faz Oluşturabilme Adına Yüksek Gürültü Seviyesine Sahip Medikal İmgelerin Konvansiyonel Yöntemlerle Grup Halinde Hizalandırılmaları.....	34
Alkolsüz Yağlı Karaciğer Hastalığı Tanısında Yapay Zekâ	62
Artificial Intelligence In Clinic Microbiology Laboratories	63
Sürekli Diyabet Takip Sistemi: Cgm Cihazı	65
Diyabette Giyilebilir Teknolojiler.....	67
Diyabetin Öz Yönetiminde Beslenme Ve Fiziksel Aktivite Davranışlarını Destekleyen E-Sağlık Teknolojileri.....	69
Postpartum Emzirme Süreci Ve Sanal Gerçeklik	71
Ebelik Mesleğinde Yeni Bir Bakış Açısı: Girişimcilik	73
A New Perspective In Midwifery Profession: Entrepreneurship	74
Hemşirelik Eğitiminde İnovatif Uygulamalar	75
Tıp Eğitiminde Yapay Zeka Ürünlerinin Kullanımına Etik Bakış.....	76
Hasta Eğitiminde İnovatif Yaklaşımlar	78
Geriatrik Bireylerin Yaşamında Kolaylaştırıcı İnovatif Uygulamalar	84
Ebelik Eğitiminde Karma Gerçeklik	86

Proposed Parallel DenseNet Model for Anomaly Detection in Musculoskeletal System - Hand Part X-Ray Images

Selahattin GÜÇLÜ¹, Durmuş ÖZDEMİR², Hamdi Melih SARAĞLU³

Abstract

Deep learning is not only a technical tool with wide application possibilities, but also has an important function in the field of image recognition. Considering the theoretical value and practical importance of image recognition technology in promoting the development of computer vision and artificial intelligence, this study aims to develop the DenseNet model, which is a deep learning application in image recognition. In the proposed Parallel DenseNet model, 3x3 convolution layers are used instead of 1x1 to capture or extract features in larger areas. A new convolution block was designed in parallel to take full advantage of the existing features and to avoid adding too many parameters. MURA (musculoskeletal radiographs) dataset, which is Stanford University's open dataset, was used for training hand X-ray images. 1513 healthy and 1538 anomaly hand X-ray images; AlexNet, DenseNet, Parallel DenseNet and Proposed Parallel DenseNet deep learning models were used for anomaly detection and the analysis results were compared. In our study, the most successful model was found to be the Proposed Parallel DenseNet model (66.16%) with a test accuracy value for the hand part. The test accuracy values of the next models are AlexNet model (59.39%), Parallel DenseNet model (59.17%) and classical DenseNet model (57.64%), respectively. As a result, it is found that the Proposed Parallel DenseNet model is more successful than the other deep learning models in terms of test accuracy in anomaly detection of hand X-ray images.

Keywords: DenseNet; deep learning; convolution layer

¹Department of Electrical and Electronics Engineering, Kutahya Dumlupinar University, Kutahya 43100, Türkiye, selahattin.guclu@dpu.edu.tr

²Department of Software Engineering, Kutahya Dumlupinar University, Kutahya 43100, Türkiye, durmus.ozdemir@dpu.edu.tr

³Department of Electrical and Electronics Engineering, Kutahya Dumlupinar University, Kutahya 43100, Türkiye, hmelih.saraoglu@dpu.edu.tr

Derin Öğrenme Modelleriyle Kemik Kırıklarının Tespiti

Mehmet Ali GEDİK¹, Cüneyt ÖZDEMİR²

Giriş ve Amaç

Kemik, insan vücudunun temel yapı taşlarından biridir ve sağlıklı bir yaşam için kritik öneme sahiptir. Ancak, çeşitli travmatik olaylar veya tıbbi durumlar sonucunda kemiklerde kırıklar meydana gelebilir. Kemik kırıkları, bu kırılmaların tıbbi bir tanımıdır ve genellikle ciddi yaralanmalara veya sağlık sorunlarına yol açabilirler [1-3]. Tıbbi görüntüleme, modern tıbbin temel unsurlarından biridir ve hastalıkların teşhisinde ve tedavisinde kritik bir rol oynamaktadır. Geleneksel olarak, kemik kırıklarının teşhisinde yaygın olarak kullanılan bir yöntem, radyografiler veya X-ışınlarıdır. Bu görüntüler, kemiklerin yapısını detaylı bir şekilde gösterir ve kırıkların varlığını belirlemek için kullanılır.

Ancak, radyografik görüntülerin yorumlanması zaman alıcı ve öznel bir süreç olabilir. Ayrıca, bu yöntem, tüm kırık tiplerini her zaman açıkça göstermeyebilir ve tanısal doğrulukta değişkenliklere neden olabilir. Bu nedenle, daha doğru ve etkili bir teşhis yöntemi arayışı, tıbbi görüntüleme alanında sürekli bir araştırma konusudur. Derin öğrenme, son yıllarda tıbbi görüntüleme alanında önemli bir ilerleme kaydetmiştir. Özellikle, evrişimli sinir ağları gibi derin öğrenme modelleri, görüntülerden karmaşık desenleri algılayabilir ve öğrenebilir. Bu modeller, kemik kırıklarının teşhisinde ve sınıflandırılmasında geleneksel yöntemlere alternatif olarak değerlendirilmektedir. Derin öğrenme modelleri, radyografik görüntüler üzerinde otomatik analiz yapabilir ve kırıkların tespitini ve sınıflandırılmasını gerçekleştirebilir. Bu, teşhis sürecini hızlandırabilir ve radyologların yükünü azaltabilir. Kismet ve arkadaşları [4] derin öğrenme ile ortopedi ve travmatoloji alanında kırık tespitinde umut verici sonuçlar elde etmiştir. Hsieh ve diğerleri tarafından yapılan çalışmada derin öğrenmenin kemik mineral yoğunluğu ve kırık riski tahmininde kullanılması, bu tekniklerin kemik sağlığı alanında çeşitli uygulamalara sahip olduğunu belirtmiştir [5]. Ayrıca, Hardalaç ve arkadaşları bilek kırıklarının tespiti için yenilikçi bir model sunarak kırık tespitinde daha spesifik uygulamaların geliştirilmesine katkı sağlamıştır [6]. Bu araştırma, kemik kırıklarının derin öğrenme modelleriyle sınıflandırılması üzerinde yoğunlaşmıştır. Özellikle, tıbbi görüntüleme alanındaki bu

¹ Dr. Öğr. Üyesi, Kütahya Sağlık Bilimleri Üniversitesi, mehmetaligedik@gmail.com, <https://orcid.org/0000-0002-1548-0444>

² Dr. Öğr. Üyesi, Siirt Üniversitesi, cozdemir@siirt.edu.tr, <https://orcid.org/0000-0002-9252-5888>

yenilikçi yaklaşımların kemik kırıkları üzerindeki etkinliği ve potansiyeli incelenmiştir. Çalışmada, kemik kırıklarının sınıflandırılması için 16 farklı transfer öğrenme modeli kullanılmıştır. En başarılı bulunan model ve bu modelin kemik kırıkları üzerindeki performansı detaylı bir şekilde araştırılmıştır.


Materyal ve Yöntem

Bu çalışmada, kemik kırıklarının sınıflandırılmasında kullanılmak için FracAtlas [7] veri kümesi kullanılmıştır. FracAtlas, kas-iskelet sistemi kemik kırıklarını tanımlamak için kullanılmıştır. Toplamda, FracAtlas veri seti 4083 görüntüden oluşmaktadır; bunların 717'si "fractured" (kırık) olarak etiketlenmiştir, geri kalanı ise "non-fractured" (kırıksız) olarak sınıflandırılmıştır. Bu veri kümesi, derin öğrenme görevlerine ek açıklamalar içeren bir kas-iskelet sistemi kemik kırığı veri setidir. COCO, VGG, YOLO ve Pascal VOC formatlarında 4.083 direkt grafi içermektedir. Veri kümesinde yer alan sınıflara ait görüntü dağılımı tablo 1'de gösterilmiştir.

Tablo 1. Veri kümesi dağılımı

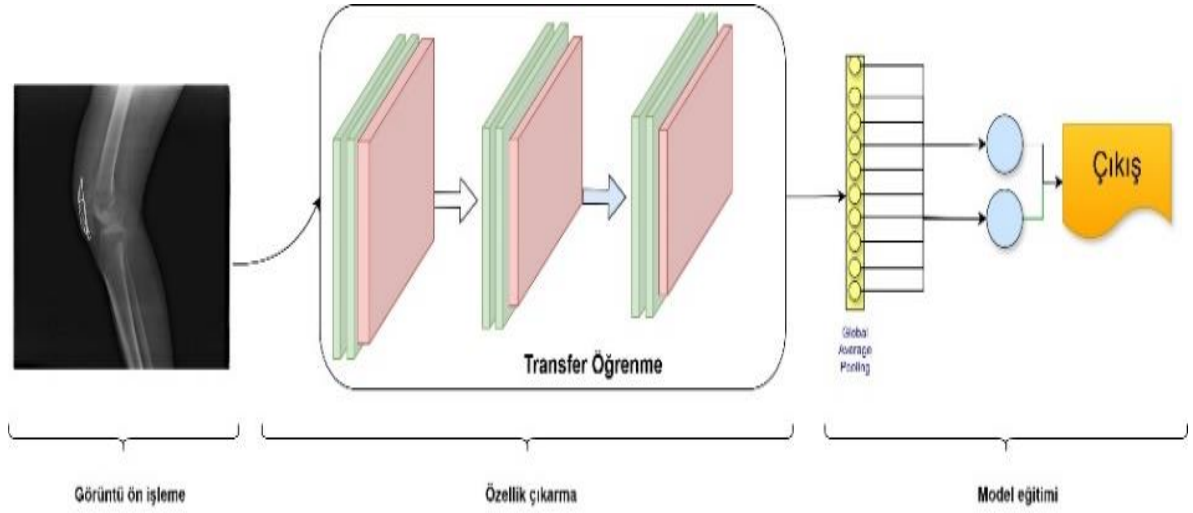
	Toplam
Fractured	717
No Fractured	3366
Toplam	4083

Veri kümesinden farklı sınıflara ait örnek görüntüler Şekil 1'de gösterilmiştir.



Şekil 1. Veri kümesine ait farklı görüntüler

Bu çalışmada, kemik kırıklarının sınıflandırılması amacıyla 28 farklı transfer öğrenme modeli kullanılmıştır. Bu modeller Xception, VGG16, VGG19, ResNet50, ResNet50V2, ResNet101, ResNet101V2, ResNet152, ResNet152V2, InceptionV3, InceptionResNetV2, MobileNet, MobileNetV2, DenseNet121, DenseNet169, DenseNet201, NASNetMobile, EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3, EfficientNetB4, EfficientNetB5, EfficientNetV2B0, EfficientNetV2B1, EfficientNetV2B2, EfficientNetV2B3 ve EfficientNetV2S modellerini içermektedir. Bu modeller, derin öğrenme tekniklerini kullanarak kemik kırıklarını sınıflandırmak için eğitilmiş ve test edilmiştir. Kemik kırıklarını sınıflandırmak için kullanılan model mimarisi şekil 2’de gösterilmiştir.



Şekil 2. Model Mimarisi

Model eğitimi sırasında temel hiperparametreler belirlenmiştir. İlk olarak, görüntülerin normalleştirilmesi işlemi gerçekleştirilmiştir. Bu adım, piksel değerlerinin belirli bir aralığa sıkıştırılması amacıyla uygulanmıştır. Ayrıca, aşırı uydurmayı önlemek için Erken Durdurma (Early Stopping) tekniği kullanılmıştır. Eğitim sürecinde, modelin validasyon doğruluk metriğinde belirli bir süre boyunca ilerleme göstermediği durumlarda, öğrenme oranı azaltma işlemi gerçekleştirilmiştir. Optimizasyon algoritması olarak Adam algoritması tercih edilmiştir. Ayrıca, görüntüler 224x224 piksel boyutlarına yeniden boyutlandırılmıştır.

Bulgular

Kemik kırıklarının sınıflandırmak için veri kümesi üzerinde 28 farklı transfer öğrenme modeline ait deneysel sonuçlar Tablo 2'de gösterilmiştir. Sonuçlar, her bir modelin test doğruluğunu, hassasiyetini, duyarlılığını, F1 skorunu ve alan altı eğrisi (AUC) değerini içermektedir. Bu sonuçlar, her bir modelin kemik kırığı sınıflandırmasındaki performansını karşılaştırmak ve değerlendirmek için temel teşkil etmektedir. Bu çalışmada kullanılan metriklerden AUC değeri, modellerin ROC (Receiver Operating Characteristic) eğrisinin altındaki alanı temsil eder. Bu değer, bir modelin farklı eşik değerlerinde performansını ölçmek için kullanılır. ROC eğrisi, duyarlılık (recall) ve özgüllük (specificity) arasındaki ilişkiyi gösteren bir grafikdir. Yüksek bir AUC değeri, modelin hem yüksek duyarlılık hem de yüksek özgüllük sağladığını gösterir. Hassasiyet (precision), doğru pozitif sınıflandırmaların toplam pozitif sınıflandırmalara oranını ifade eder. Duyarlılık (recall), gerçekte pozitif olan tüm örneklerin doğru şekilde tanımlandığının oranını gösterir. F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasını sağlayarak, bu iki metriğin birleştirilmiş bir ölçüsünü sunar.

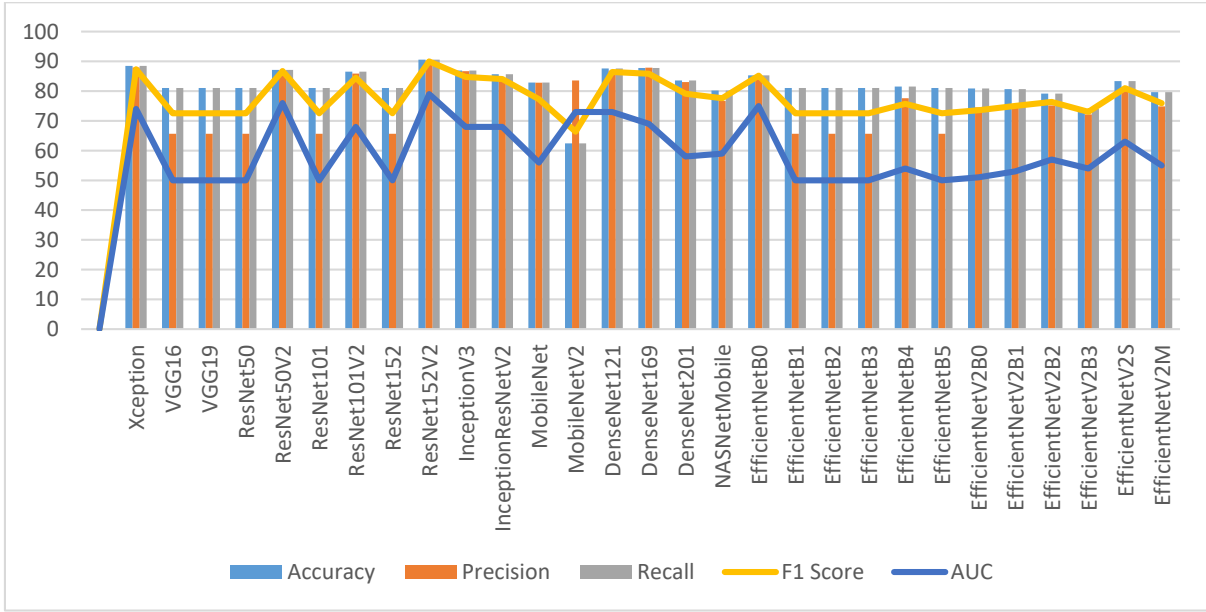
Tablo 2. Transfer Öğrenme Modellerinin Performans Metrikleri

Model	Accuracy (%)	Precision (%)	Recall (%)	F1 Score (%)	AUC (%)
Xception	88.49	87.96	88.49	87.36	74.00
VGG16	81.03	65.66	81.03	72.54	50.00
VGG19	81.03	65.66	81.03	72.54	50.00
ResNet50	81.03	65.66	81.03	72.54	50.00
ResNet50V2	87.15	86.54	87.15	86.74	76.00
ResNet101	81.03	65.66	81.03	72.54	50.00
ResNet101V2	86.54	85.91	86.54	84.51	68.00
ResNet152	81.03	65.66	81.03	72.54	50.00
ResNet152V2	90.58	90.20	90.58	90.00	79.00
InceptionV3	86.90	86.72	86.90	84.75	68.00
InceptionResNetV2	85.68	84.38	85.68	84.05	68.00
MobileNet	82.86	82.82	82.86	77.29	56.00
MobileNetV2	62.42	83.60	62.42	66.34	73.00
DenseNet121	87.64	86.86	87.64	86.45	73.00
DenseNet169	87.76	87.87	87.76	85.85	69.00
DenseNet201	83.60	83.05	83.60	79.10	58.00
NASNetMobile	80.17	76.70	80.17	77.59	59.00
EfficientNetB0	85.31	85.10	85.31	85.20	75.00
EfficientNetB1	81.03	65.66	81.03	72.54	50.00
EfficientNetB2	81.03	65.66	81.03	72.54	50.00
EfficientNetB3	81.03	65.66	81.03	72.54	50.00
EfficientNetB4	81.52	77.63	81.52	75.75	54.00
EfficientNetB5	81.03	65.66	81.03	72.54	50.00
EfficientNetV2B0	80.91	74.57	80.91	73.56	51.00
EfficientNetV2B1	80.66	75.06	80.66	75.04	53.00
EfficientNetV2B2	79.19	75.21	79.19	76.38	57.00
EfficientNetV2B3	74.05	72.16	74.05	73.03	54.00
EfficientNetV2S	83.35	81.14	83.35	81.02	63.00
EfficientNetV2M	79.68	74.87	79.68	75.93	55.00

Tablo 2’de, makalede kullanılan transfer öğrenme modellerinin FracAtlas veri seti üzerinde elde ettiği performans metrikleri sunulmuştur.

Tablo 2’ye göre, ResNet152V2 modeli, yüksek doğruluk, hassasiyet, duyarlılık ve F1 skoru ile dikkat çekmektedir. Ayrıca, ROC eğrisi altındaki alanı en geniş olan modeldir, bu da en yüksek AUC değerine sahip olduğunu gösterir. Dolayısıyla, ResNet152V2 modeli, hem doğru pozitifleri hem de doğru negatifleri etkili bir şekilde sınıflandırdığını kanıtlar niteliktedir. Diğer bir dikkate değer model olan Xception, iyi performans sergileyen diğer bir modeldir. Özellikle,

DenseNet169 modeli yüksek doğruluk ve F1 skoru ile ön plana çıkmaktadır, bu da görüntü sınıflandırma görevinde etkili bir performans gösterdiğini göstermektedir. Ancak, VGG16, VGG19, ResNet50, ResNet101, ResNet152, MobileNetV2 ve EfficientNetB1 üzerindeki tüm modellerin performansı diğerlerine kıyasla daha düşüktür. Bu modellerin kemik kırığı sınıflandırma görevinde daha az etkili olduğunu göstermektedir. ‘8 farklı transfer öğrenme modelinin farklı metriklerdeki performans sonuçları şekil 3’te gösterilmiştir.



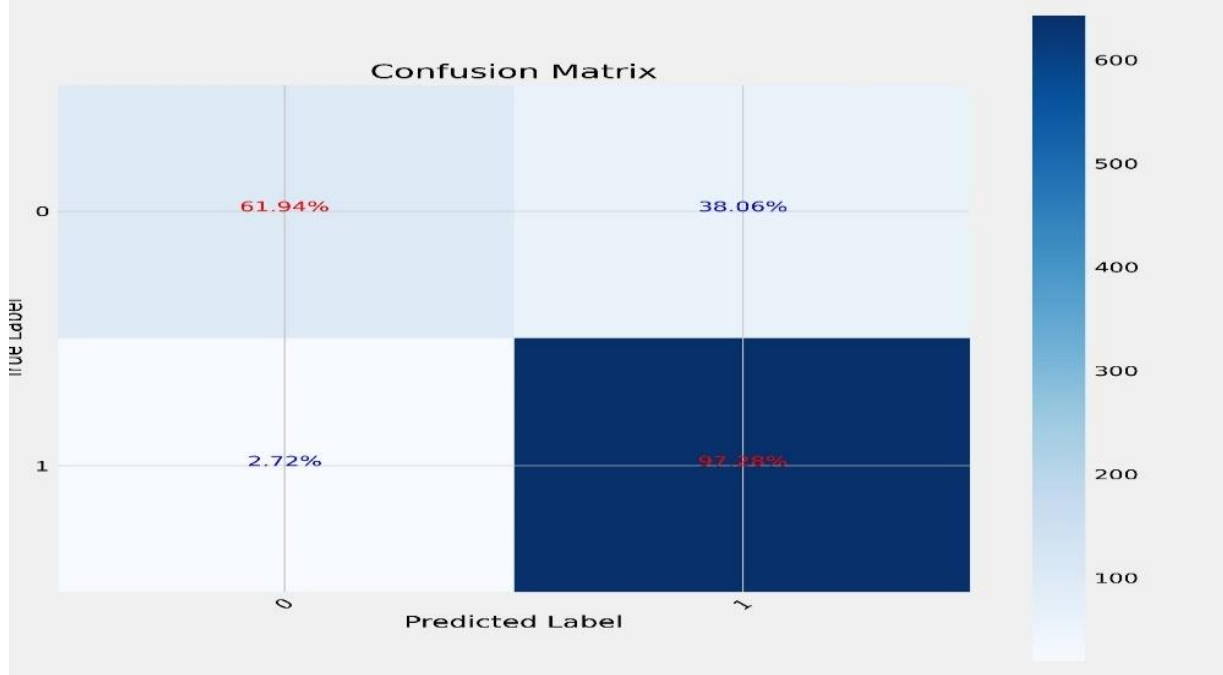
Şekil 3. Farklı transfer öğrenme model performanslarının kıyaslanması

En iyi performansı gösteren ResNet152V2 modelinin accuracy ve loss grafiği şekil 4’te gösterilmiştir.



Şekil 4. ResNet152V2 Modeline ait loss ve accuracy grafiği

ResNet152V2 modeline ait karmaşıklık matrisi Şekil 5'te sunulmuştur. Karmaşıklık matrisi, gerçek sınıflar ile modelin tahmin ettiği sınıflar arasındaki ilişkiyi görselleştirir.



Şekil 4. ResNet152V2 Modelinin karmaşıklık matrisi

Şekil 5'ten görüldüğü gibi 61.94% oranında, gerçekte "Kırıklı" olan 717 örneği doğru bir şekilde sınıflandırılmıştır. 97.28% oranında, gerçekte "Kırıklı Değil" olan 3366 örneği doğru bir şekilde sınıflandırılmıştır. 2.72% oranında, gerçekte "Kırıklı" olan 717 örneği "Kırıklı Değil" olarak yanlış sınıflandırılmıştır. 38.06% oranında, gerçekte "Kırıklı Değil" olan 3366 örneği "Kırıklı" olarak yanlış sınıflandırılmıştır.

Genel olarak, bu analiz, görüntü sınıflandırma görevi için en iyi performansı gösteren modellerin ResNet152V2, DenseNet169 ve Xception olduğunu ortaya koymaktadır. Bu modeller, farklı performans metriklerinde en üst düzeyde performans sergileyerek, kemik kırığı tespiti konusunda potansiyel olarak etkili araçlar olarak değerlendirilebilir.

Sonuç

Bu çalışmada, kemik kırıklarının sınıflandırılması için 28 farklı transfer öğrenme modelleri kullanılarak derin öğrenme yöntemleriyle başarılı sonuçlar elde edilmiştir. Yapılan deneysel çalışmalar, ResNet152V2, DenseNet169 ve Xception gibi önde gelen model mimarilerinin kemik kırığı tespiti görevinde en yüksek performansı sergilediğini göstermektedir. Bu modeller, test doğruluğu, hassasiyet, duyarlılık ve F1 skoru gibi metriklerde diğer modellere kıyasla üstün bir performans sergilemişlerdir. Ayrıca, AUC değerleri incelendiğinde, ResNet152V2 modelinin ROC eğrisi altındaki alanı en geniş olan model olduğu görülmüştür,

bu da modelin genel sınıflandırma yeteneğinin yüksek olduğunu göstermektedir. Sonuçlar, derin öğrenme tabanlı transfer öğrenme modellerinin, kemik kırığı sınıflandırma görevinde etkili araçlar olarak kullanılabileceğini ve klinik uygulamalarda önemli bir rol oynayabileceğini göstermektedir. Bu modeller, kemik kırığı tanısında doktorlara destek sağlayarak tanı sürecini hızlandırabilir ve tedaviye daha erken müdahale etme imkânı sunabilir. Ancak, daha geniş veri kümeleri ve çeşitli klinik senaryoların değerlendirilmesi, modelin genelleştirilebilirliğini ve gerçek dünya uygulanabilirliğini daha fazla doğrulayabilir.

Anahtar Kelimeler: Kemik kırığı; Derin öğrenme; Transfer öğrenme; Görüntü sınıflandırma; Tıbbi görüntüleme

KAYNAKÇA

1. Mandal S, Greenblatt A.B, An J. Imaging intelligence: AI is transforming medical imaging across the imaging spectrum; IEEE Pulse; 2018;9(5); 16-24; doi:10.1109/MPUL.2018.2857226
2. Meena T, Roy S. Bone fracture detection using deep supervised learning from radiological images: A paradigm shift. Diagnostics, 2022;12(10); doi:10.3390/diagnostics12102420
3. Eastwood D. Breaks without bruises. Are common and can't be said to rule out non-accidental injury; BMJ;1998;317(7166); 1095-1096
4. Kalmet PH, Sanduleanu S, Primakov S, Wu G, Jochems A, Refaee T, et al. Deep learning in fracture detection: a narrative review. Acta orthopaedica; 2020; 91(2): 215-220.
5. Hsieh C.I, Zheng K, Lin C, Mei L, Lu L, Li W. Et al. Automated bone mineral density prediction and fracture risk assessment using plain radiographs via deep learning. Nature communications;2021;12(1); 5472.
6. Hardalaç F, Uysal F, Peker O, Çiçeklidağ M, Tolunay T, Tokgöz, N, et al. Fracture detection in wrist X-ray images using deep learning-based object detection models. Sensors; 2022;22(3); 1285.
7. Abedeen I, Rahman M.A, Protyasha F.Z, Ahmed T, Chowdhury T.M, Shatabda S. Fracatlas: A dataset for fracture classification, localization and segmentation of musculoskeletal radiographs. Scientific Data; 2023; 10(1): 521.

Eslem ALTIN¹, Elif AYDIN¹, Güllü KAYMAK¹, Meliha KOLDEMİR Gündüz¹, Ayşe KOÇAK¹

Özet

Yapay zeka (AI), insanın bilişsel süreçlerini kopyalamak için tasarlanmış programların geliştirilmesini ve karmaşık verilerin analizini içeren bir bilgisayar bilimi alanıdır. Ağırlıklı olarak görsel temelli bir tanı alanı olan dermatolojide yapay zeka, özellikle Psoriasis'in (sedef hastalığının) tanısında profesyonel süreçlerin iyileştirilmesinde giderek daha önemli hale gelmiştir. Sedef hastalığındaki mevcut AI uygulamaları temelde 3 ana başlık altında toplanabilir: (i) teşhis, sınıflandırma, lezyon segmentasyonu, lezyon şiddeti ve PASI skorlaması dahil tanı; (ii) tahmin tedavi etkinliği ve tahmin aday ilaçları da dahil olmak üzere tedavi; (iii) e-sağlık ve koruyucu hekimlik de dahil olmak üzere hastalığın yönetimi'dir. Son yıllarda, cilt lezyonlarını tespit etmek ve sedef hastalığını tanımlayıp sınıflandırmak için yapay zeka algoritmalarının uygulanmasında önemli ilerlemeler kaydedildi. Bu algoritmalar dermatologlarınkine benzer veya onu aşan performanslar göstermiştir. Çalışmalarda psoriatic lezyonları tanımlamak için, yüksek dereceli spektrumlar, doku ve renk de dahil olmak üzere ciltte baskın özellik seçimi için temel bileşen analizi (PCA) ile machine learning ML tekniklerini kullandıkları bir dizi çalışma yürüttüler. Bu özellikler daha sonra %100 sınıflandırma doğruluğu ile 540 cilt görüntüsünü sağlıklı veya hastalıklı olarak sınıflandırmak için kullanılan destek vektör makinesi (SVM) sınıflandırıcılarına beslendi. Sedef hastalığı içeren bir görüntüyü tanımladıktan sonra püstüler, guttat, ters, plak ve eritrodermik dahil olmak üzere mevcut sedef hastalığının farklı tiplerini sınıflandırmak gerekir. Ancak bu sınıflandırmadan sonra sedef hastalığının tedavisine başlanabilir. Bunu başarmak için doğru sınıflandırma ve sınıflandırma modellerini geliştirmek için evrişimli sinir ağları (CNN'ler) ve uzun kısa süreli bellek olmak üzere iki deep learning (DL) algoritması kullanılmış ve sırasıyla %84,2 ve %72,3 doğruluk elde edilmiştir. Bu sonuçlar, dermatolojik tanıda DL uygulamalarının gelecekteki potansiyelini ortaya koymakta ve daha doğru ve daha doğru yöntemlerin önünü

¹ Kütahya Sağlık Bilimleri Üniversitesi, Tıp Fakültesi

açmaktadır. Sedef hastalığında ilacın etkinliğini tahmin etmek için istatistiksel ve makine öğrenme tekniklerini kullanılmıştır. Enflamasyonla ilişkili proteinleri ve kardiyovasküler hastalıkla ilişkili proteinleri tespit eden hasta kan örneklerini kullanarak, belirli bir hastanın 12 haftalık tofasitinib veya etanersept tedavisinden sonra PASI 75 yanıtı verip vermeyeceğini tahmin eden bir sınıflandırıcı geliştirdiler. Bu, potansiyel biyobelirteçleri tanımlamak ve etkinin moleküler mekanizmasını anlamak için etanersept tedavisinin 6. ve 12. haftalarında periferik kan mononükleer hücrelerinin global gen ekspresyon profilini analiz ettikleri başka bir deneye benzer karakterde bir algoritmaydı. Bu algoritma modeli, %91,88'lik bir genel doğruluk gösterdi (yanıt verenler için %90 ve yanıt vermeyenler için %93,75). Sonuçlar, yeni potansiyel terapötik adayların belirlenmesine ek olarak, sedef hastalığının tedavisinde halihazırda kullanılan birçok ilacı da kapsamaktadır.

Anahtar Kelimeler: Psoriasis, Yapay zeka, Deep learning

Sağlık Hizmetleri Ve Eğitiminde Yapay Zeka Kullanımı: Büyük Dil Modelleri (Llm) Ve Üretken Çekişmeli Ağ Modelleri (Gan)

Abdullah Alper EFE¹ , Halil İbrahim ÖZDEMİR² , Özlem ARIK³

Özet

Yapay zeka, insan zekâsından esinlenerek insan gibi düşünme karar verme yöntemidir. Yapay zeka ile öğrenme, sınıflandırma, anlam çıkarma, problem çözme, karar verme, ayırt etme gibi işlemler yapılabilmektedir. Yapay zekânın temel sektörlerdeki artan kullanımı sağlık alanında da kullanımlarının araştırılması gerektiğini göstermiştir. Ayrıca, son yıllarda Büyük Dil Modellerindeki gelişmeler ve Üretken Çekişmeli Ağlardaki güncel yaklaşımlar sağlık alanında önemli bir potansiyele sahiptir. Bu teknolojilerin sağlık alanındaki kullanımlarının incelenmesi, mevcut bilgilerin ve bu alandaki çalışmaların bir derlemesinin yapılması, sağlık sektöründe yeni ve etkili çözümlerin geliştirilmesine katkı sağlayabilir. Bu çalışmada nitel olan araştırma tekniklerinden derleme yapılmıştır. Literatürden yapay zekanın, doğal dil işleme, büyük dil modelleri ve üretken yapay zeka ile ilgili ve bunların sağlık alanında kullanımları ile ilgili literatür taramaları yapılmıştır. Yapılan taramalarda yapay zeka ile tanı koyma ve tedavi planlama konularında da yardımcı uygulamaların geliştirilebileceği gözlenmiştir. Doğal dil işleme modelleri ile insanların doğal konuşma dilinin metne çevrilmesi işlenmesi sağlanmıştır. Çeşitli soru cevap makineleri, bilgi arama gibi çalışmalar yapılmıştır. Dil modelleme ile konuşulanların hızlıca metne aktarılması klinik olarak kararların daha hızlı kaydedildiğini göstermiştir. Büyük dil modelleri ile birlikte özellikle insan dilinin karmaşık yapıları daha rahat anlayabilir ve daha anlaşılabilir cevaplar üretebilir hale gelmiştir. Bu modeller ile radyoloji raporlarının işlenmesi, dokümanlarından bilgiler çıkarılması ile hastanelerde de bilgilerin daha verimli kullanılabileceği gözlenmiştir. Üretken çelişmeli ağlarda birbiriyle rekabet eden iki ağın birlikte çalışmasıyla görüntü ve metin sentezlerinde uygulamalar için uygun altyapı potansiyeli sunmuştur. GAN (Generative Adversarial Networks) ağlarının üretken yanının olması diğer ağlara göre daha farklı olmasını sağlamaktadır. Bu üretkenliği sayesinde problemler için farklı

¹ Dr. Öğr. Üyesi, Kütahya Sağlık Bilimleri Üniversitesi, abdullahalper.efe@ksbu.edu.tr, OiD:0000-0002-7561-6745

² Öğr. Gör., Kütahya Sağlık Bilimleri Üniversitesi, halilibrahim.ozdemir@ksbu.edu.tr, OiD:0000-0003-1225-0413

³ Dr. Öğr. Üyesi, Kütahya Sağlık Bilimleri Üniversitesi, ozlem.arik@ksbu.edu.tr, OiD: 0000-0002-9427-3733

alternatif çözüm yollarının geliştirilmesinde yararlanılabilir. Üretken ağların özellikle tıbbi görüntülerin artırılması, çözünürlük iyileştirme, ilaç geliştirme gibi alanlarda fayda sağlayabileceği gözlenmiştir. Ayrıca GAN ağı kişiselleştirilmiş ilaç ve tedavi geliştirme konusunda da yardımcı olabileceği gözlenmiştir. GAN ağları ile LLM (Large Language Models) ağlarının beraberce kullanımlarıyla oldukça verimli modellerin geliştirilebileceği ve modellerin sağlık alanında klinik hasta iletişimine yardımcı olabileceği gözlenmiştir. Bu iki modelin beraberce çalışmasıyla tıbbi görüntülerin ve sağlık verilerinin doğal dil işlemedeki becerileri ve üretken yapıları sayesinde bu verilerin yorumlanabileceği ve hekimlere karar almada destek olabileceği görülmektedir. LLM ve GAN modellerinin sağlık alanında henüz yeni geliştiği ve çok yeni bir alan olduğu, bu alanda etik ve güvenilirlik gibi sorunlar olduğu gözlemlenmiştir.

Utilization of Artificial Intelligence in Healthcare Services and Education: Large Language Models(LLM) and Generative Adversarial Network Models

SUMMARY

Artificial intelligence (AI) is a method of decision-making inspired by human intelligence. AI enables processes such as learning, reasoning, comprehension, problem-solving, classification, decision-making, and discrimination to be performed similarly to humans. The increasing use of AI across various sectors has underscored the need for exploration of its applications in the healthcare domain. Furthermore, recent advancements in Large Language Models (LLMs) and state-of-the-art approaches in Generative Adversarial Networks (GANs) hold significant potential in the healthcare sector. Investigating the utilization of these technologies in healthcare, compiling existing knowledge and research in this field, could contribute to the development of novel and effective solutions within the healthcare industry. In this study, a compilation was conducted using qualitative research techniques. Literature reviews were conducted on Artificial Intelligence, Natural Language Processing, Large Language Models, and Generative Artificial Intelligence, as well as their applications in the healthcare domain. The reviews revealed the potential for developing assistive applications in

diagnosis and treatment planning using artificial intelligence. Natural Language Processing models were employed to convert human natural speech into text. Various studies, including question-answering systems and information retrieval, were examined. The rapid conversion of spoken language into text through language modeling has demonstrated the expedited recording of clinical decisions. Particularly with large language models, the comprehension of complex structures in human language has become more feasible, enabling the generation of more understandable responses. The processing of radiology reports and extraction of information from documents using these models has been observed to enhance the efficient utilization of data in hospitals. Generative adversarial networks, operating with competing networks, offer potential infrastructure for applications in image and text synthesis. The generative aspect of GANs distinguishes them from other networks, facilitating the development of alternative solution pathways for solutions. It has been observed that generative networks can provide benefits, particularly in areas such as enhancing medical images, improving resolution, and drug development. Additionally, GAN networks have been observed to assist in personalized drug and treatment development. The combined use of GAN networks with LLMs allows for the development of highly effective conversational models and can assist in clinical patient communication in the healthcare field. Through the collaborative operation of these two models, it is observed that medical images and health data can be interpreted due to their natural language processing capabilities and generative structures, thereby aiding physicians in decision-making. It is noted that LLM and GAN models are still nascent in the field of healthcare, posing ethical and reliability concerns.

Giriş

Yapay zeka uygulamaları hemen hemen her alanda önemli bir yer edinmiştir. Son zamanlarda, yapay zeka büyük veri setlerini kullanarak önemli çıktılar vermiştir. Sağlık sektörü, farklı alt alanlar ve karmaşık süreçler içeren yapısıyla bu teknolojiden en çok etkilenen alanlardan biridir [1]. Özellikle son 30 yılda tıp bilimi ve teknolojisi hızla ilerlemiştir. Tıp, büyük veri, bulut bilişim ve yapay zeka tabanlı karar destek yazılımları aracılığıyla başta görüntü işleme ve tanı koyma, tedavi planlama ve ilaç geliştirme gibi konular olmak üzere yaygın olarak kullanılmaktadır [2,3]. Özellikle sağlık uygulamalarında (i) erken teşhis ve tedavi uygulamalarına yardımcı, (ii) hasta bakımında iyileştirme, (iii) elektronik sağlık kayıtlarının analizi, (iv) operasyonel verimlilik ve maliyet azaltma konularında avantajlar sunmaktadır. Üretken yapay zeka iki farklı yapay sinir ağı modelini eğiterek özgün ve gerçeğe yakın veriler üretebilen derin öğrenme modelidir [4]. Büyük Dil Modelleri (LLMs), büyük miktarda metin

verisi üzerinde eğitilmiş yapay zeka modelleridir. Bu modeller, insan dilini anlayabilir ve üretebilir, metinleri özetleyebilir, farklı diller arasında çeviri yapabilir ve çeşitli yaratıcı metin formatları oluşturabilirler [5].

Tiwari ve arkadaşları (2023) yaptıkları çalışmada Teknoloji Kabul Modeli temelinde eğitim ve öğrenme amaçlı olarak yeni ortaya çıkan yapay zeka aracı Chat Generative Pre-Trained Transformer (ChatGPT) kullanmaya yönelik öğrenci tutumunu belirlemek amacıyla 375 öğrenci üzerinde en küçük kareler yöntemiyle hipotezlerini incelemişlerdir. Araştırma, öğrenci popülasyonunun büyük oranda ChatGPT aracını kullanmaya motive olduğunu ve eğitim bağlamında faydalı ve güvenilir bulduklarını ortaya koymaktadır [6].

Arısoy ve arkadaşları (2023) yaptıkları çalışmada 873 sağlık hizmetleri MYO öğrencisinin demografik bilgileri ile birlikte enfeksiyon hastalıklarına yatkınlık değerlendirilmesi amacıyla veriler toplanmış ve toplanan veriler lojistik regresyon, rastgele orman vb. makine öğrenmesi yöntemleri ile değerlendirilmiştir. Yapılan çalışma sonucunda diğer 4 yöntem içerisinde en başarılı tahminleme yapan lojistik regresyon yöntemi ile %74.7 oranında başarı ile yeni gelen öğrencilerin enfeksiyona yakalanma yatkınlıklarının tahmin edilmesi sağlanmıştır [7].

Öcal ve arkadaşları (2020) 262 Tıp fakültesi öğrencisi üzerinde yaptıkları kesitsel çalışmada Öğrencilerin %59.2'si (n:242) tıpta yapay zeka uygulamaları hakkında bilgi sahibi olmadığını, %79.2'si (n:324) ise ileride meslek hayatında yapay zekayı kullanmayı istediğini, öğrencilerin yarısından azı bilgi sahibi olduğunu ifade ederken, %87'si eğitim verilmesini istediğini bildirmiştir. Yapay zekanın tıpta kullanımı ile ilgili, gelecekte sağlık hizmeti sunucusu olacak olan tıp fakültesi öğrencilerinin eğitim müfredatında bu konunun yer almasının önemli olduğu ve bu alanda daha kapsamlı çalışmalar yapılmasının gerekliliği sonucuna varılmıştır [8].

Yiğit ve arkadaşları (2023) ise ChatGPT uygulamasının sağlık hizmetlerinde sağladığı imkânları ve kullanımıyla ilgili potansiyel sınırlamaları ve endişeleri incelemiştir. Çalışmanın bulgularında ChatGPT sağlık alanında görev yapan profesyonellere bilimsel yayın hazırlama aşamalarında, eğitim süreçlerinin planlanmasında ve sağlık hizmetleri uygulamalarında çeşitli imkânlar sunduğu, özellikle Sağlık hizmeti alanlarında kişiselleştirilmiş tıbbi tedaviyi, halka kolay erişilebilirliği ve anlaşılır sağlık bilgileri sağlayarak sağlık okuryazarlığını geliştirme potansiyeline sahip olduğu belirtilmiştir. Araştırmanın sonucunda ChatGPT gibi üretken yapay zeka araçlarının sağlık hizmetlerindeki kullanımını inceleyen ve bu alandaki yenilikleri teşvik eden araştırmaların yapılmasına ihtiyaç olduğu belirtilmiştir [9].

Sağlık alanında her geçen gün yapay zeka uygulamaları gelişirken çok kısa bir zaman dilimi içerisinde sağlık çalışanlarının yapay zeka tabanlı sağlık çözümlerine adapte olması gerekecektir. Bu nedenle sağlık hizmetleri ve eğitiminde yapay zeka kullanımı bağlamında Büyük Dil Modelleri (LLMs) ve Üretken Çekişmeli Ağ Modelleri (GANs) teknolojilerin sağlık alanındaki kullanımlarının incelenmesi, mevcut bilgilerin ve alandaki çalışmaların derlemesinin yapılması, sağlık sektöründe yeni ve etkili çözümlerin geliştirilmesine katkı sağlayacağı düşünülmektedir.

OpenAI tarafından geliştirilen Chatgpt modelinin son yıllardaki soruları yanıt verme başarısındaki artış ve büyük dil modellerindeki bu gelişmelerin sağlık eğitimi ve hizmetlerinde de kullanımlarını konusunda da beklentileri artırmaktadır [10]. Doğal Dil İşleme ve Konuşma Tanıma teorisi alanında yapılan çalışmalar ile birlikte artık günümüzde çeşitli konuşma tanıma uygulamaları geliştirilmektedir [11].

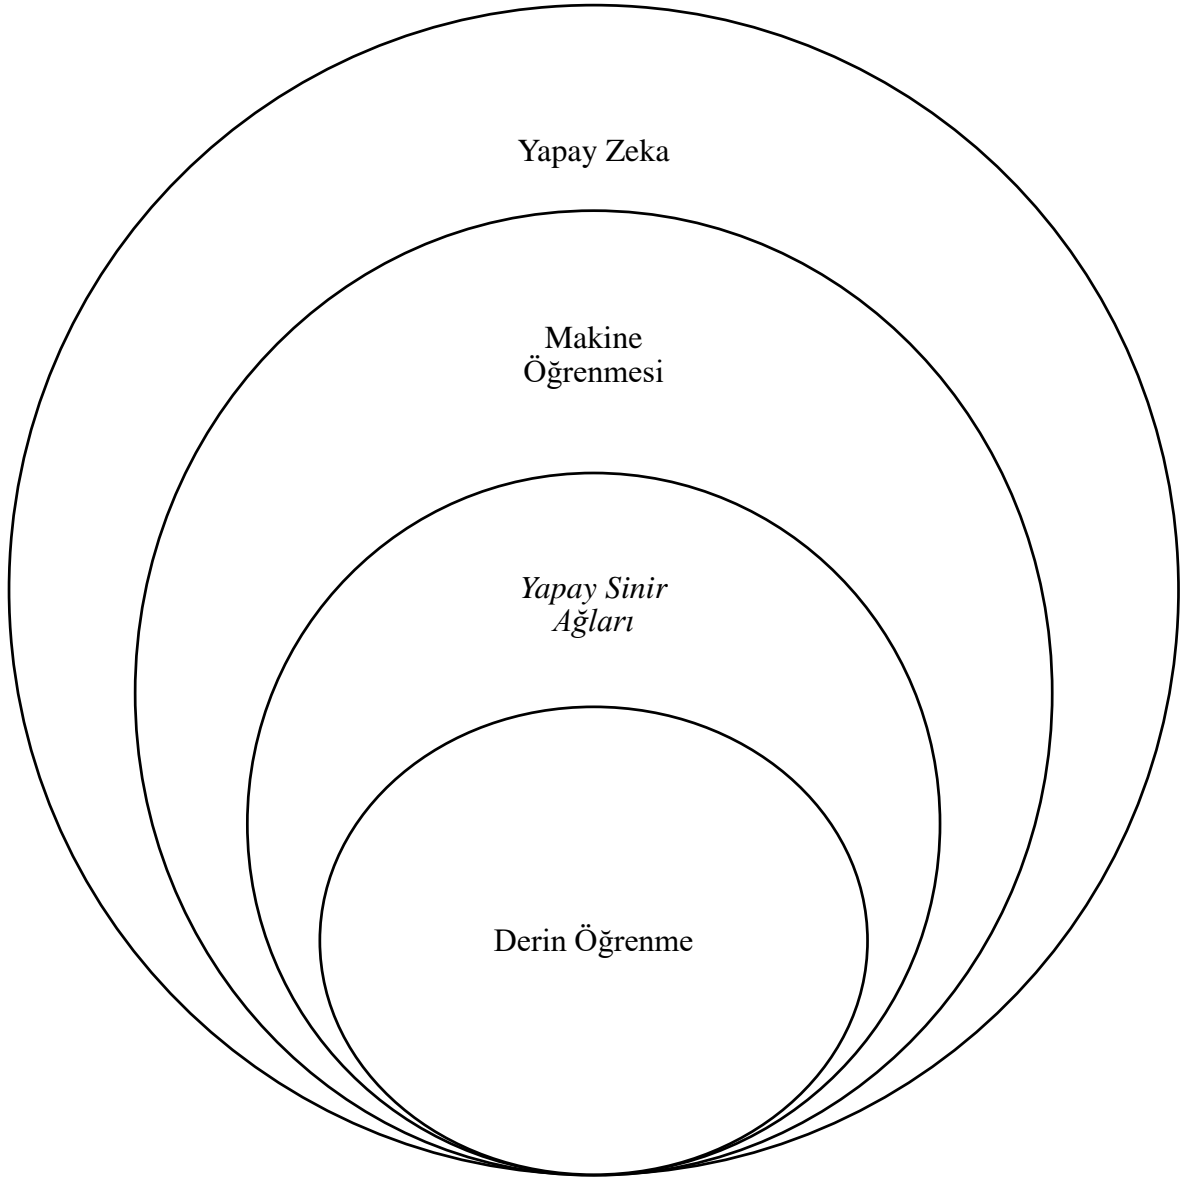
Bu çalışmanın amacı; Sağlık Hizmetleri ve Eğitiminde Yapay Zeka Kullanımını LLM ve GAN Modelleri perspektifinde incelemektir. Ayrıca bu çalışma ile Doğal Dil İşleme, Büyük Dil Modelleri ve Üretken Çekişmeli Ağların temel çalışma mantığı ve kullanım örnekleri de sunulmuştur.

Çalışmada nitel araştırma yöntemlerinden derleme yöntemi kullanılmıştır. Bu derleme çalışmasında, Sağlık Hizmetleri ve Eğitimi alanlarında Üretken Yapay Zeka teknolojilerinin nasıl etki ettiğini görmek için Web of Science, IEEE xplore, Academic Search Complete (EBSCO), Directory of Open Access Journal (DOAJ), ProQuest Dissertations & Theses Global, Google Akademik, TR Dizin ve Yükseköğretim Tez Merkezi indeksleri taranarak bulunan araştırmalar analiz edilmiştir. Araştırma makaleleri, yayımlanmış tezler ve konuyla ilgili birçok bilimsel ve güncel yayın sistematik olarak incelenmiştir. Özellikle Sağlık Hizmetleri ve Eğitimi alanlarında bu teknolojilerin mevcut durumuyla ilgili çalışmaların yanı sıra, gelecekteki potansiyel uygulama alanlarına ilişkin öneriler de sunulmuştur.

Yapay Zeka

Yapay zekâ, insan zekâsından esinlenerek insan gibi düşünme karar verme yöntemidir. Yapay zeka kavramı literatürde ilk kez John McCarthy tarafından zeki makineler olarak ortaya konulmuştur [12,13].

Yapay zeka yöntemlerinden olan makine öğrenme yöntemleri ile birlikte veriler üzerinde sınıflandırma, tahmin, kümeleme gibi işlemler yapılmaktadır. Yapay zeka yöntemlerinden olan yapay sinir ağları, biyolojik olarak sinir hücrelerinin taklidiyle birlikte oluşmuş ağlardır. Şekil 1'de yapay zeka alt alanları görülmektedir. Bir üst halkada ise akıllı sistemler bulunmaktadır.



Şekil1: Yapay Zeka Alt Alanları (Russell &Norving (2021)'den uyarlanmıştır [14]

Yapay zeka teknolojilerindeki algoritma ve katmanların artışları ile birlikte ve bu katmanların daha verimli çalışmaları ile birlikte derin öğrenme yaklaşımları günümüzde yerini almıştır.

Makine öğrenmesi gibi yöntemler daha basit problemlerde kullanılırken, derin öğrenme konusundaki yaklaşımlar ile daha karmaşık problemlerin çözümlerinde derin öğrenme algoritmaları geliştirilmektedir.

Derin öğrenme ile görüntü sınıflandırma, üretme, sıkıştırma gibi başlıca işlemler yapılmaktadır. Bunun yanı sıra video işleme ve sinyal işleme gibi alanlarda da çeşitli çalışmalar yapılmaktadır.

Derin öğrenme ayrıca metinler üzerinde işlemler yapabilir hale gelmiş ve daha da geliştirilmektedir. Örneğin metnin özetini çıkarma, metinden bilgiler çıkarma ve sohbet robotları konusunda kullanımları yaygınlaşmıştır.

Doğal Dil İşleme

Doğal dil işleme, insanlarla ile bilgisayarların etkileşim sağlamasını sağlayan, insanların konuşma dilinin bilgisayarlardan tarafından anlaşılmasıdır. Doğal dil işleme teknolojisi dil bilimciler ile bilgisayar bilimleri alanlarının beraberce çalışmaları ile geliştirilen bir alandır. Bir cümlenin öznesi, ekleri, köklerinin bilgisayar ve yapay zeka ile bulunması alanında çalışmalar yürüten bir bilim dalıdır [15]. Doğal dil işleme teknolojisi, soru-cevap makineleri, diller arası çeviri sistemleri, bilgi arama ve metin özetleme gibi amaçlarla kullanılmaktadır [16].

Doğal dil işleme teknolojileriyle ayrıca yazım hatalarının denetimi de yapılmaktadır. Yazılan metinlerde yapılan hataların denetlenmesinde kullanılır [17]. Doğal dil işleme teknolojileri, teknoloji alanında özellikle makinelere veri girişinde yapay zeka desteğiyle insanın konuşma sesinin elektronik sinyallerinin tanımlanması ile birlikte metne çevrilmesini sağlar. Aynı zamanda dönüştürülen metin üzerinden doğal dil işleme teknolojileri ile anlamlandırılması sağlanır.

Büyük Dil Modelleri

Büyük Dil Modelleri (LLM'ler), son yıllarda yapay zeka (AI) araştırmalarının en heyecan verici alanlarından biri haline gelmiştir. Bu modeller, insan dilini daha önce mümkün olandan daha karmaşık ve hassas bir şekilde anlayabilir ve üretebilir hale gelmiştir. LLM'lerin potansiyel uygulama alanları oldukça geniştir ve çeviri, metin özetleme, soru cevaplama, yaratıcı içerik üretimi vb. yapabilmektedir [18].

LLM'lerin temelini oluşturan teknolojinin temelleri 1950'lere kadar uzanmaktadır [19]. Ancak, bu modellerin gerçek potansiyeli, 2010'larda Transformer gibi yeni sinir ağı mimarilerinin geliştirilmesiyle ortaya çıkmıştır [20]. Transformer modeli, dildeki uzun mesafeli bağımlılıkları daha iyi yakalayabilme yeteneği sayesinde, LLM'lerin gelişmesinde önemli bir rol oynamıştır.

Generative Pre-trained Transformer (GPT), OpenAI tarafından geliştirilen ve büyük metin veri kümeleri üzerinde eğitilen bir dil modelidir. GPT'nin ilk versiyonu 2018 yılında yayınlanmış ve dil modelleme, çeviri, soru cevaplama ve metin özetleme gibi çeşitli görevlerde önemli bir başarı elde etmiştir [21].

2020 yılında GPT-3'ün piyasaya sürülmesi, LLM'ler alanında bir dönüm noktası olmuştur. 175 milyar parametrelili GPT-3, insan dilini daha önce mümkün olandan daha karmaşık ve ayrıntılı bir şekilde anlayabilme ve üretebilme yeteneğine sahipti [22]. GPT-3'ün başarısı, LLM'lerin potansiyelini ve yapay zeka araştırmalarında yeni bir çağın başlangıcını göstermiştir.

2022'de GPT-4'ün tanıtımı, GPT teknolojisinin gelişiminde bir sonraki adımı temsil etmektedir. 500 milyar parametrelili GPT-4, GPT-3'ün yeteneklerini geliştirmeye devam etmektedir ve daha karmaşık ve yaratıcı dil görevlerini yerine getirebilmektedir [23].

Üretken Çekişmeli Ağlar

Üretken çekişmeli ağlar (GAN'lar), son yıllarda yapay zeka alanında önemli bir ilgi odağı olmuştur. Bu derin öğrenme modeli, birbirleriyle rekabet eden iki ağı birlikte çalışmasıyla önceki veriler üzerinden yeni veri üretme yeteneği sunar ve bu da özellikle görüntü ve metin sentezi gibi alanlarda çeşitli uygulamalar için potansiyel sağlar. Ancak, GAN'ların eğitimi ve istikrarlı sonuçlar elde etmek için gereken kaynaklar üzerindeki bağımlılığı, bu teknolojinin daha geniş ölçekte benimsenmesini engelleyen bazı zorlukları da beraberinde getirir [24, 25, 26].

Bu ağın diğer derin öğrenme yöntemlerine göre en büyük farkı üretken bir yapısının olmasıdır. GAN'lar bir üretici ve bir ayırıcı olmak üzere iki bileşenden oluşurlar. Üretici bileşeninde giriş olarak verilen görüntü üzerine gürültüler eklenir. Ayırıcı bileşeninde ise gürültü eklenmiş resimler gerçek görüntülerinden ayırt edilmeye çalışılır [27, 28].

Üretken çekişmeli ağlar genel olarak, çözünürlük artırma, görüntü üretimi, video üretimi ve görüntü düzenleme alanlarında kullanılır [28,29].

Sağlık alanında Doğal Dil İşleme ve Büyük Dil Modellerinin Kullanımı

Sağlık alanında doğal dil işleme (NLP) ve büyük dil modellerinin kullanımı, tıp literatüründeki metinlerin otomatik analizi, hastalık teşhisi, tedavi önerileri ve hasta bakımı gibi çeşitli uygulamalarda önemli bir rol oynamaktadır [30]. Büyük dil modelleri, hastaların sağlık kayıtlarını anlamak ve klinik kararlar için bilgi sağlamak gibi karmaşık dil yapılarını işleme yetenekleriyle dikkat çekmektedir. Bu teknolojilerin sağlık sektöründe yaygın olarak benimsenmesi, hastaların bakımının iyileştirilmesi ve sağlık hizmetlerinin daha verimli bir şekilde sunulması için önemli bir potansiyel sunmaktadır [31].

Delibaş (2008) yılında yaptığı çalışmada Türkçe yazım hatalarının ayıklanması ve düzeltilmesi amacıyla doğal dil işleme teknolojisiyle çalışma yapmıştır [17]. Albayrak ise (2020) yaptığı çalışmada doğal dil işleme tekniklerini Apache Spark NTK paketini kullanarak, Veri Bilimi ve Uygulamaları dersi ile ilgili lisansüstü ders içeriklerinin hazırlamasını gerçekleştirmiştir [32].

Öztürk ve arkadaşları (2020) yılında yaptıkları çalışmada X platformu (eski ismiyle twitter) üzerindeki kullanıcıların yazmış olduğu twitlerin hastalık konulu olup olmadığı ve bununla birlikte hastalık türlerinin tespiti amacıyla çalışma yapmışlardır [33]. Taşkiran (2021) yılında yaptığı çalışmada doğal dil işleme ve makine öğrenmesini kullanarak akademik metinler üzerinde kümeleme işlemleri gerçekleştirilmiştir [34].

Toğaçar ve arkadaşları (2022) yaptıkları çalışmada internet üzerinden yayınlanan sahte haberlerin tespiti amacıyla doğal dil işleme teknolojisiyle çalışma yapmışlardır ve doğruluk başarıları %91.48 ile haberlerin sahte olup olmadığını sınıflandırmıştır [35]. Yılmaz ve arkadaşları ise (2021) yaptıkları derleme çalışmasıyla doğal dil işleme alanında kullanılan popüler açık kaynak kodlu kütüphanelerle ilgili araştırma sunmuşlardır [36].

Aktaş ve arkadaşları (2017) yılında yaptıkları çalışmada bilgisayar ağları ile ilgili terimlerin WordNet ontolojisine uyarlamışlardır. Verilen paragrafta yer alan bilgisayar ağ terimlerinin ontolojik sözlükte aranması sağlanmış ve sözlükte bulunmayan kelimeler ise otomatik ontolojiye ekleme çalışmasını yürütmüşlerdir [37]. Tablo 1’de Sağlık alanında doğal dil işleme ve büyük dil modellerinin kullanım örnekleri literatürden ön plana çıkan güncel çalışmalarla listelenmiştir. Tabloda öncelikle çalışmaların veri seti, model ve başarı boyutları incelenmiştir.

Tablo 1: Sağlık alanında Doğal Dil İşleme ve Büyük Dil Modellerinin Kullanım Örnekleri

Çalışmanın başlığı	Veri seti	Model	Başarı
Twitter verilerinden doğal dil işleme ve makine öğrenmesi ile hastalık tespiti [34]	Twitterdaki kullanıcıların yazmış oldukları mesajların	Gözetimli ve gözetimsiz makine öğrenmesi algoritmaları, TF-IDF ve BOW yöntemleri	%97.48
Radyoloji Raporları için Türkçe Bilgi Çıkarım Sistemi [38]	Ardışık 756 abdominal USG incelemesine ait rapor	TRBÇS tasarlandı	GÇO : 92 Duyarlılık : 97
Covid-19 Dokümanları Üzerinde Geliştirilen Sağlıkta Bir Yapay Zeka Uygulaması [39]	Google Scholar platformunda yer alan sağlık alanındaki akademik çalışmalar taranarak veriseti oluşturulmuştur	Kelime vektörleri, Word2Vec metodu, Yapay Sinir Ağları	%91
Derin Öğrenme Yöntemleri ile Mortalite ve Hastanede Kalma Süresinin Tahmini [40]	MIMIC-III	Zaman Serisi Modeli, Derin öğrenme tabanlı Çoklu-model Mimarisi Sentence-BERT	Hastanede Mortalite : 88.43 ± 0.003 , Yoğun Bakımda Mortalite : 89.00 ± 0.003 Yoğun Bakımda Kalma > 3 Gün: 70.25 ± 0.004 Yoğun Bakımda Kalma > 7 Gün: 75.14 ± 0.002
Psy-LLM: Yapay Zeka Tabanlı Geniş Dil Modelleriyle Küresel Ruh Sağlığı Psikolojik Hizmetlerini Artırma [41]	Yapay Zeka Araştırma Enstitüsü, Tsinghua Üniversitesi PsyQA kullanıp dataset içinde 56000 yapılandırılmış veriden 5000'i seçilerek çalışma yapılmıştır.	Psy-LLM framework	Perplexity, ROUGE-L ve Distinct-n gibi metriklerle dil modelinin çevrimiçi psikolojik danışmada uygunluğu test edilmiştir.
Health-LLM: Kişiselleştirilmiş Erişim-Artırılmış Hastalık Tahmin Sistemi [42]	dataset IMCS-21.	Health-LLM	%83

Sağlık Hizmetleri ve Eğitiminde Üretken Çekişmeli Ağların Kullanımı

Sağlık hizmetleri ve eğitiminde üretken çekişmeli ağların (GAN'lar) kullanımı, tıbbi görüntülerin iyileştirilmesi, hastalık teşhisi, cerrahi eğitim simülasyonları ve hasta eğitim materyalleri gibi çeşitli alanlarda giderek artan bir şekilde araştırılmaktadır [43]. GAN'lar, gerçekçi tıbbi görüntüler üretme yetenekleri ve özgün veri sentezleme kabiliyetleriyle dikkat çekmektedir, bu da özellikle tıbbi eğitimde ve hasta bakımında yenilikçi yaklaşımların geliştirilmesine olanak tanır [44, 46]. Ancak, GAN'ların güvenilirliği, etik sorunlar ve klinik uygulamalardaki pratik kullanımı gibi konularda daha fazla araştırma ve standartlar belirlenmesi gerekmektedir.

Üretken Çekişmeli Ağların gelişimine alanyazın ışığında göz atıldığında; ilk olarak 2014 yılında Goodfellow ve arkadaşları tarafından öncü çalışmalar yapıldığı görülmektedir [45]. O zamandan beri, GAN'lar önemli bir gelişme göstermiştir. Derin öğrenme algoritmalarındaki gelişmeler, donanım teknolojilerindeki artış ve sağlık verilerinin kullanılabilirliğindeki ilerleme GAN'ların önde gelen gelişimi faktörlerinden sayılabilir. GAN'lar, sağlık alanında büyük bir potansiyele sahiptir. GAN'ların gelişmesi ve sağlık verilerinin kullanılabilirliğinin artması ile birlikte, GAN'ların sağlık hizmetlerinde ve sağlık eğitiminde daha yaygın olarak kullanılması beklenmektedir [44].

Üretken çekişmeli ağlar (GAN'lar), son yıllarda sağlık alanında önemli bir araştırma konusu haline gelmiştir. GAN'lar, sentetik veri üretme, görüntüyü iyileştirme, ilaç keşfi ve hastalık teşhisi gibi çeşitli sağlık görevlerinde yararlı olabilecek güçlü bir araçtır [46].

Üretken Çekişmeli Ağlar, sağlık hizmetlerinde çeşitli görevlerde kullanılabilir. Örneğin, GAN'lar: Sentetik hasta verileri üretmek için kullanılmakta, böylece, doktorların ve araştırmacıların nadir hastalıkları veya karmaşık tıbbi prosedürleri daha iyi anlamalarına yardımcı olmaktadır [47]. GANlar, tıbbi görüntülerden gürültüyü ve artefaktları çıkarmada kullanılır. Bu, doktorların teşhis koymalarını ve hastaların tedavisini planlamalarını kolaylaştırmaktadır. [48]. Ayrıca GAN'lar kişiselleştirilmiş ilaç ve tedaviler geliştirmek için kullanılabilir. Bu, hastaların tedavilere daha iyi yanıt vermelerine ve yan etkilerin azalmasına yardımcı olabilir [49].

Sağlık Eğitiminde Üretken Çekişmeli Ağların (GAN) kullanımı, tıbbi tarama, teşhis, simülasyon, eğitim materyalleri oluşturma olarak özetlenebilir. Tıbbi tarama ve teşhis için tıp öğrencilerine sanal hastalar sunmak için kullanılmakta bu da öğrencilerin klinik becerilerini geliştirmelerine ve gerçek hastalara bakmadan önce deneyim kazanmalarına yardımcı olmaktadır [50].

Benzer şekilde GAN'lar karmaşık tıbbi prosedürleri simüle etmek için kullanılarak cerrahların ve diğer sağlık uzmanlarının yeni teknikler öğrenmelerine ve riskleri en aza indirmelerine yardımcı olma potansiyeli yüksektir. GAN'ların bir diğer kullanım alanı da Hasta eğitimi materyalleri oluşturmaktır. Bu, hastaların kendi sağlıkları hakkında daha fazla bilgi edinmelerine ve tedavilerine daha iyi uymalarına yardımcı olabilir. Bunun yanında, Tablo 2'de sağlık hizmetleri ve eğitiminde GAN ağlarının kullanımı literatürden başlıca örnekleri kullanılan veri seti, model ve başarı boyutlarıyla tablo halinde listelenmiştir.

Tablo 2: Sağlık Hizmetleri ve Eğitiminde Üretken Çekişmeli Ağların Kullanım örnekleri

Çalışmanın Başlığı	Veri Seti	Model	Başarı
Gelişmiş üretken çekişmeli ağları kullanarak elektronik sağlık kayıtlarının sentezlenmesi [40]	MIMIC-III	modified medGAN	% 64
Elektronik Sağlık Kayıtları için Üretken Çekişmeli Ağlarla Derin Öğrenme Risk Tahminini Artırma [51]	Gerçek dünya uyumlu Elektronik Sağlık Kayıt veritabanı	CNN-BASIC CNN-RAND CNN-FULL SSL-SMIR SSL-LGC SSL-GAN	% 85
Üretken Çekişmeli Ağlar Kullanarak Kümeleşmiş Sağlık Bakımı Veri Analizinin Sınıflandırılması (GAN) [52]	Akciğer kanseri (kaggle) Arrhythmia dataset(kaggle)	GAN	%97.8 dataset 1, %98.6 dataset 2
GAN Kullanarak Küçük Tıbbi Veri Seti Sınıflandırma Performansının Artırılması [53]	UCI Makine öğrenmesi kayıtlarından ve Keel'den elde edilmiştir	GAN	En iyi sonuç, Göğüs kanseri: 0.9738
Üretken Çekişmeli Ağlar Kullanarak Sağlık Hizmeti Sağlayıcılarının Denetimsiz Anomali Tespiti [54]	Medicare Dataset COIDA Dataset	GAN-AD SHAP	LR 0.802 Medicare dataset için, LR 0.992 dataset COIDA için

Sonuç ve Öneriler

Bu çalışmada; Sağlık Hizmetleri ve Eğitiminde Yapay Zeka Kullanımı bağlamında Büyük Dil Modelleri(LLM) ve Üretken Çekişmeli Ağ Modelleri(GAN) genel çözümlenmesi ve tanımlayıcı bilgiler ortaya koyulması amacıyla derinlemesine yapılan bir alanyazın incelemesi ortaya koymaktadır. Böylece, yapay zekânın sağlık alanındaki kullanım potansiyelini değerlendirmek için kapsamlı bir inceleme sunulmuştur. Yapılan derleme çalışması, yapay zekâ, büyük dil modelleri ve üretken çekişmeli ağlar gibi teknolojilerin sağlık hizmetlerindeki rolünü vurgulamış ve gelecekteki araştırmalara yol gösterecek bir temel oluşturmuştur [9,10,11,18,19,21]. Özellikle, yapay zekânın tıbbi görüntüleme, teşhis ve tedavi planlaması gibi alanlarda nasıl kullanılabileceği üzerinde durulmuş ve bu teknolojilerin sağlık sektöründe etkili çözümler sunabileceği belirtilmiştir.

Sağlık hizmetlerinde yapay zeka uygulamalarının artmasıyla, özellikle büyük dil modelleri ve üretken çekişmeli ağ modelleri gibi teknolojilerin sağlık sektöründeki etkinliği ve örnek kullanımları kıyaslamalı tablolarla incelenmiş ve bu alandaki araştırmaların önemi vurgulanmıştır [34,38,41 ,42,40,51]. Ancak, bu yeni teknolojilerin güvenilirlik ve etik konuları da dikkate alınmalıdır [55]. Bu çalışmalar, sağlık alanında yapay zeka temelli çözümlerin geliştirilmesine ve sağlık hizmetlerinin daha etkili ve verimli bir şekilde sunulmasına katkı sağlayabilir. Gelecekteki çalışmaların, yapay zekânın sağlık alanındaki uygulamalarını daha da

geliştirmek ve bu teknolojilerin sağlık kurumlarında nasıl daha etkin bir şekilde kullanılabileceğini araştırmak üzerine odaklanması gerekmektedir.

Anahtar Kelimeler: Yapay zeka; büyük dil modelleri; üretken çekişmeli ağlar; sağlık hizmetleri; sağlık eğitimi.

KAYNAKÇA

1. Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: a structured literature review. *BMC medical informatics and decision making*, 21, 1-23.
2. Dicuonzo, G., Donofrio, F., Fusco, A., & Shini, M. (2023). Healthcare system: Moving forward with artificial intelligence. *Technovation*, 120, 102510.
3. Morrow, E., Zidaru, T., Ross, F., Mason, C., Patel, K. D., Ream, M., & Stockley, R. (2023). Artificial intelligence technologies and compassion in healthcare: A systematic scoping review. *Frontiers in Psychology*, 13, 971044.
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
5. Amodei, D., Cruz, F., Jou, A., Kos, R., Lemley, J., Milhune, B., ... & Yost, B. (2016). Concrete problems in AI safety. *arXiv preprint arXiv:1606.06565*.
6. Tiwari, C. K., Bhat, M. A., Khan, S. T., Subramaniam, R., & Khan, M. A. I. (2023). What drives students toward ChatGPT? An investigation of the factors influencing adoption and usage of ChatGPT. *Interactive Technology and Smart Education*.
7. Arısoy, F. M., Karakaş, Ü., Şahinoğlu, M. S., Alkan, S., vd. (2023). Makine Öğrenmesi Enfeksiyonu Önleyebilir Mi? Sağlık Hizmetleri Meslek Yüksekokulu Öğrencilerinin Enfeksiyon Hastalıklarına Yatkınlık Değerlendirmesi. *Sağlık Bilimlerinde Eğitim Dergisi*, 6(1), 25-32.
8. Öcal, E. E., Emrah, A. T. A. Y., Önsüz, M. F., Algın, F., Çokyigit, F. K., Kılınç, S., & Yiğit, F. N. (2020). Tıp fakültesi öğrencilerinin tıpta yapay zeka ile ilgili düşünceleri. *Türk Tıp Öğrencileri Araştırma Dergisi*, 2(1), 9-16.
9. Yiğit, S., Berşe, S., & Dirgar, E. (2023). Yapay Zeka Destekli Dil İşleme Teknolojisi Olan ChatGPT'nin Sağlık Hizmetlerinde Kullanımı. *Eurasian Journal of Health Technology Assessment*, 7(1), 57-65.
10. Küçükler, M. (2023). Muhasebede Yapay Zeka Uygulamaları: Chatgpt'nin Muhasebe Sınavı. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 33(2), 875-888.
11. Yalçın, N. (2008). Konuşma Tanıma Teorisi ve Teknikleri. *Kastamonu Eğitim Dergisi*, 16(1), 249-266.
12. McCarthy J. What is artificial intelligence? Computer Science Department, Stanford University. Available from: <http://www-formal.stanford.edu/jmc/whatisai.pdf>
13. Demirhan, A., Kılıç, Y. A., & İnan, G. (2010). Tıpta yapay zeka uygulamaları.
14. Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson Education.
15. Adalı, E. (2012). Doğal dil işleme. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(2).
16. Seker, S. E. (2015). Doğal Dil İşleme (Natural Language Processing). *YBS Ansiklopedi*, 2(4), 14-31.

17. Delibas, A. (2008). Doğal dil işleme ile Türkçe yazım hatalarının denetlenmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü).
18. LeCun, Y., Bengio, Y., & Hinton, G. (2021). Deep learning. *Nature*, 521(7553), 436-444.
19. Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. In *Advances in neural information processing systems* (pp. 3111-3119).
20. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. arXiv preprint arXiv:1706.03762.
21. Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving language understanding by generative pre-training. URL <https://s3-us-west-2.amazonaws.com/openai-assets/research-covers/language-2>
22. Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. arXiv preprint arXiv:2005.14165.
23. Sutskever, I., & OpenAI Team. (2022). GPT-4: Generative Pre-trained Transformer 4. URL <https://openai.com/blog/openai-api/>
24. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Bengio, Y., & Courville, A. C. (2014). Generative adversarial networks. In *Proceedings of the 31st International Conference on Machine Learning (ICML-14)*, pp. 1722-1730. <https://arxiv.org/abs/2203.00667>
25. Brock, A., Donahue, J., & Simonyan, K. (2016). A framework for adversarial learning. In *Proceedings of the 33rd International Conference on Machine Learning (ICML-16)*, pp. 1922-1934. <https://arxiv.org/abs/1612.00334>
26. Karadeniz, M. E. (2022). Generatif Çekişmeli Ağlar (GAN'lar) ve Görüntü İşlemede Uygulamaları. Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik Haberleşme ve Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi.
27. Goodfellow, I., NIPS 2016 Tutorial: Generative Adversarial Networks, arXiv:1701.00160, (2016).
28. Çelik, G., & Talu, M. F. (2020). Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(1), 181-192.
29. Wu, X., Xu, K. ve Hall, P., A survey of image synthesis and editing with generative adversarial networks, *Tsinghua Sci. Technol.*, 22, 6, 660–674,(2017).
30. Choi, Y., Baek, M., Park, J., & Kim, S. (2022). Large language models for medical question answering. In *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 6452-6462. <https://arxiv.org/abs/2204.06272>
31. Jiang, X., Chen, Y., Dou, D., Li, Y., Wang, Z., & Won, J. (2023). Natural language processing for clinical decision support: A systematic review. *Journal of Biomedical Informatics*, 135, 102457.
32. Albayrak, A. (2020). Doğal dil işleme teknikleri kullanılarak disiplinler arası lisansüstü ders içeriği hazırlanması. *Bilişim Teknolojileri Dergisi*, 13(4), 373-383.
33. Öztürk, A., Durak, Ü., & Badıllı, F. (2020). Twitter verilerinden doğal dil işleme ve makine öğrenmesi ile hastalık tespiti. *Konya Journal of Engineering Sciences*, 8(4), 839-852.
34. Taşkırın, S. F. (2021). Doğal dil işleme ile akademik metinlerin kümelenmesi (Master's thesis, Konya Teknik Üniversitesi).
35. Toğaçar, M., Eşidir, K. A., & Ergen, B. (2021). Yapay Zeka Tabanlı Doğal Dil İşleme Yaklaşımını Kullanarak İnternet Ortamında Yayınlanmış Sahte Haberlerin Tespiti. *Journal of Intelligent Systems: Theory and Applications*, 5(1), 1-8.
36. Yılmaz, H., & Yumuşak, S. (2021). Açık kaynak doğal dil işleme kütüphaneleri. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1), 81-85.
37. Aktaş, Y., İnce, E. Y., & Çakır, A. (2017). Doğal dil işleme kullanarak bilgisayar ağ terimlerinin wordnet ontolojisinde uyarlanması. *Teknik Bilimler Dergisi*, 7(2), 1-9.

38. Sosyal, E., Çiçekli, N. B., & Baykal, N. (2009). Radyoloji Raporları için Türkçe Bilgi Çıkarım Sistemi. *VI. Ulusal Tıp Bilişimi Kongresi, Antalya, Türkiye*, 304-312.
39. Aydoğan, M., & Sener, A. (2020). An Artificial Intelligence Application in Health Developed on Covid-19 Documents. *Journal of Health, Medicine and Nursing*, 75, 58-66.
40. Baowaly, M. K., Lin, C. C., Liu, C. L., & Chen, K. T. (2019). Synthesizing electronic health records using improved generative adversarial networks. *Journal of the American Medical Informatics Association*, 26(3), 228-241.
41. Lai, T., Shi, Y., Du, Z., Wu, J., Fu, K., Dou, Y., & Wang, Z. (2023). Psy-llm: Scaling up global mental health psychological services with ai-based large language models. *arXiv preprint arXiv:2307.11991*.
42. Jin, M., Yu, Q., Zhang, C., Shu, D., Zhu, S., Du, M., ... & Meng, Y. (2024). Health-LLM: Personalized Retrieval-Augmented Disease Prediction Model. *arXiv preprint arXiv:2402.00746*.
43. Liu, X., Zhang, Q., Wolz, R., Yin, T., Sun, W., & Wang, S. (2022). Generative adversarial networks for medical image generation and analysis: A comprehensive review. *Medical Image Analysis*, 78, 102412. <https://arxiv.org/abs/2204.06449>
44. Shen, J., Wu, G., Wang, S., & Li, W. (2023). Generative adversarial networks for medical image synthesis and analysis: A survey. *Journal of Medical Imaging and Health Informatics*, 13(2), 220-236.
45. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial networks. *arXiv preprint arXiv:1406.2661*.
46. Akgül, B., & Ulaş, S. (2023). Tıbbi Görüntülemeye Üretken Çekişmeli Ağların (GAN'lar) Kullanımı: Bir İnceleme Çalışması. *Marmara Üniversitesi Tıp Fakültesi Dergisi*, 50(2), 11-20.
47. Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). Synthetic data augmentation using GAN for improved liver lesion segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 379-388). Springer, Cham.
48. Shin, H. C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., ... & Summers, R. M. (2018). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset selection, and training strategies. *arXiv preprint arXiv:1805.09352*.
49. Zhang, Y., Li, P., Wang, L., & Xing, E. P. (2020). Medical image synthesis for data augmentation using generative adversarial networks. *arXiv preprint arXiv:2004.09086*.
50. Bi, L., & Wang, Y. (2021). Generative adversarial networks for medical image analysis: A review. *Medical Image Analysis*, 70, 102045.
51. Che, Z., Cheng, Y., Zhai, S., Sun, Z., & Liu, Y. (2017, November). Boosting deep learning risk prediction with generative adversarial networks for electronic health records. In *2017 IEEE International Conference on Data Mining (ICDM)* (pp. 787-792). IEEE.
52. Purandhar, N., Ayyasamy, S., & Siva Kumar, P. (2022). Classification of clustered health care data analysis using generative adversarial networks (GAN). *Soft Computing*, 26(12), 5511-5521.
53. Alauthman, M., Al-Qerem, A., Sowan, B., Alsarhan, A., Eshtay, M., Aldweesh, A., & Aslam, N. (2023, March). Enhancing small medical dataset classification performance using GAN. In *Informatics* (Vol. 10, No. 1, p. 28). MDPI.
54. Naidoo, K. ve Marivate, V. (2020). Üretken çekişmeli ağlar kullanan sağlık hizmeti sağlayıcılarının denetimsiz anormallik tespiti. *Bilgi ve İletişim Teknolojisinin Sorumlu Tasarımı, Uygulanması ve Kullanımı: 19. IFIP WG 6.11 e-İş, e-Hizmetler ve e-Toplum Konferansı, I3E 2020, Skukuza, Güney Afrika, 6-8 Nisan 2020, Bildiriler Kitabı*, Bölüm 19 (s. 419-430). Springer Uluslararası Yayıncılık.

55.Çınar, A., & Ünlü, E. I. (2023). SRGAN ile Süper Çözünürlüklü OCT Görüntüleri Oluşturma.

Yapay Zeka Ve Melanoma: Klinikte Kullanımı

Ayşegül CIVAN¹, Elif AYDIN¹, Güllü KAYMAK¹, Meliha Koldemir GÜNDÜZ¹, Ayşe KOÇAK¹

Özet

Melanoma, melanom dışı cilt kanserlerine kıyasla daha yüksek morbidite ve mortalite potansiyeline sahiptir. Teşhis, prognoz ve tedavisi, onkolojinin zorlu ve karmaşık alanlarından biridir. Günümüzde, dermoskopik görüntülerde ve pigmente lezyonların histopatolojik örnek sınıflandırmasında yapay zeka (AI) uygulamaları üzerinde çalışılmaktadır. Bu uygulamalar ile daha erken ve yüksek doğrulukta melanom tespitinin yanı sıra güvenilir prognoz ve terapötik yanıtın öngörülmesi amaçlanmaktadır. Melanomada pigmentli lezyonların sınıflandırılması, değişken klinik ve histolojik bulgular göz önüne alındığında; tanı, hem dermatologlar hem de patoloğlar için oldukça zorludur. Dermatologlar, epilüminesans mikroskobu (dermoskopi) kullanılmadan melanom tanısında %65- 80 doğruluk sağlayabilir. Yapay zeka (AI), dermatoloğlara bu zorlu tanı konusunda yardımcı olacak yararlı bir yardımcı araç olma potansiyeline sahiptir. Bu nedenle, dermatoloğların özellikle melanoma konusunda, yapay zeka ile birlikte çalışması gelecek için önemlidir. Yakın zamanda yapılan bir araştırma, dermatoloğların %85'inin yapay zekanın gelişmekte olan bir alan olduğunun farkında olmasına rağmen yalnızca %24'ünün konu hakkında iyi/mükemmel bilgi sahibi olduğunu bildirmiştir. Pigment lezyonu sınıflandırması için klasik makine öğrenimi teknikleri 1990'lı yılların başlarında kullanılmıştır ancak klinik görüntülere dayalı olarak pigmente lezyon sınıflandırması için evrimsel sinir ağlarını (Convolutional neural networks= CNN'ler) kullanan ilk çalışmalar 2016 yılında yayınlanmıştır. Çalışma, 170 dermoskopik olmayan klinik görüntüden (70 melanom, 100 nevüs) oluşmaktaydı ve orijinal görüntülerin kırılması, ölçeklenmesi ve döndürülmesiyle 6120 görüntü ortaya çıktı ve CNN'ler kullanıldı. Algoritma, melanom tespitinde %81 duyarlı, %80 spesifik ve %81 doğruluk sağladı. Diğer çalışmalar da %90'a varan hassasiyet ve %82-94 doğrulukla benzer veya daha iyi sonuçlar bulmuştur. Bir çalışma, önceden eğitilmiş bir CNN ile 129.450 görüntü (3.374 dermoskopi görüntüsü dahil) kullandı.

¹Kütahya Sağlık Bilimleri Üniversitesi, Tıp Fakültesi

Programın, iyi huylu nevüs ile melanomayı ayırt etme konusunda kurul onaylı yirmi bir dermatologla eşdeğer olduğu bulundu. 135 epidermal tümör klinik görüntüsü, 130 melanositik lezyon klinik görüntüsü ve 111 melanositik lezyon dermoskopi görüntüsünden oluşan bir test setinde program, biyopsi mi yapılması, lezyonun tedavi edilmesi mi yoksa hastaya güvence verilmesi mi gerektiği sorulduğunda dermatologlardan daha iyi performans gösterdi. AI ayrıca bağışıklık kontrol noktası inhibitörlerine (ICI) verilen terapötik yanıtı tahmin etmek için de kullanılmıştır. Melanom histoloji örnekleri üzerinde deep learning uygulandığında; CNN'nin hastalığın ilerlemesi açısından yüksek veya düşük riskli olarak doğru bir şekilde sınıflandırabildiğini göstermiştir. Yalnızca histolojiye dayanarak, bir CNN'nin 54 melanom vakasının ICI yanıtını tahmin edebildiğini ve yanıt verenlerin %65,2'sinin ve yanıt vermeyenlerin %74,2'sinin doğru şekilde sınıflandırıldığını göstermiştir. Gelecekte, melanoma tanı ve tedavisinde yapay zekanın klinisyenlere yardımcı bir araç olabileceğini kabul edebiliriz ancak hala klasik hekimlik günümüzde altın standarttır.

Anahtar Kelimeler: Melanoma, yapay zeka, tanı ve tedavi

Özet

Yapay zeka ve robot hemşirelik, sağlık hizmetlerinde özellikle hemşirelik girişimlerinde yeni bir tanım şeklinde gündeme gelmektedir. Hemşireler geçmişten günümüze mesleki değişimleri hızla kabul etmiş ve bununla birlikte yeni çalışma koşullarına hızla uyum sağlamışlardır. Hemşirelerin teknolojiyi nasıl kullanabileceklerini keşfetmeleri ve anlamaları mesleki gelişim açısından çok önemlidir (1). Teknolojik olanakları ve gelişmeleri takip eden, bunu anlayabilen hemşirelerin karşılaştıkları problemleri daha güvenli ve verimli biçimde çözüme kavuşturabileceği ifade edilmektedir (2). Hemşirelerin geleceklerini planlama, anlama ve mesleklerinin getirdiği değişimlere uyum sağlama becerileri yüksektir (3).

Hemşirelik hizmetleri 2000’li yıllar sonrası artarak gelişen yapay zeka olanakları ve yapay zeka ile ortaya konan robotik araçlar ile birlikte mesleki dönüşümü ortaya koymaktadır. Gelecekte meydana gelebilecek teknolojik ilerlemelerin hemşirelik mesleğine önemli katkılarının olacağı tahmin edilmektedir. Teknolojinin git gide artan hızıyla bütünleşmesi hemşirelerin, hemşirelikle alakalı teknolojik ilerlemelere duyulan ihtiyaçlarını gündeme getirmektedir (4).

Ek olarak robotlar müdahale gerektiren süreçler; damar yolu bulma, kan alma, damar yolu açma, fizyolojik ölçüm yapma, gerçekleştirilen ölçümleri yorumlama ve kaydetme gibi birçok işlevi gerçekleştirilebilmektedir. Robotlar, birey ve bireylerin yakınları ile iletişim gerçekleştirilebilirler ve bireyler hekim ile mobil uygulamalar vasıtasıyla iletişim kurabilmektedir (2). Robotlar, bireylerin fiziksel gereksinimlerini karşılama, giyinmesi, banyo yaptırma ve bireylere pozisyon verilmesi, bireylerin ev içi ve hastane odası bakım evi işlemlerini, izleme gibi süreçlerde bakım işlemlerinin sürdürülmesinde hemşirelere destek

¹ Öğretim Görevlisi, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye
ibrahimtopuz_38gs@hotmail.com, 0000-0003-0540-2095

² Öğretim Görevlisi, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye
burcu_nal@hotmail.com, 0000-0002-9469-8651

³ Doçent Doktor, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölümü, Kütahya, Türkiye
mustafanal@hotmail.com, 0000-0002-3282-1124

sunmaya girişmişlerdir (5). Bu derleme bildiride yapay zeka ve robot hemşirelerin hemşirelik mesleğine yönelik yansımalarına değinmek ve okuyucuya bu yönde bilgi sunmak amaçlanmıştır.

Anahtar Kelimeler: Hemşire; robot; yapay zeka.

KAYNAKÇA

1. Şendir M, Şimşekoğlu N, Kaya A, Sümer K. Geleceğin teknolojisinde hemşirelik. Health Sciences Journal of Nursing. 2019;1(3): 209–214.
2. Pepito JA, Locsin R. Can nurses remain relevant in a technologically advanced future?. International Journal of Nursing Sciences. 2018;6(1): 106-110. doi:10.1016/j.ijnss.2018.09.013
3. Bodur G, Kaya H. Hemşirelerin gözüyle gelecek 2050'li yıllar. Ege Üniversitesi Hemşirelik Fakültesi Dergisi. 2017;33(1): 47-58.
4. Çetin B, Eroğlu N. The value of technology in nursing care and innovation. Kocaeli Üniversitesi Acta Medica Nicomedia. 2020;3(3): 120–126.
5. Hu X, He X. Evaluation of the postoperative nursing effect of thoracic surgery assisted by artificial intelligence robot. Contrast Media Molecular Imaging. 2021;3941600. doi:10.1155/2021/3941600

Derin Öğrenme Yöntemlerine Ön Faz Oluşturabilme Adına Yüksek Gürültü Seviyesine Sahip Medikal İmgelerin Konvansiyonel Yöntemlerle Grup Halinde Hizalandırılmaları

Baranalp ÖZTÜRK¹, Ahmet BAŞTUĞ²

1. Giriş ve Amaç

Grup bazında görüntü hizalama yöntemleri, birden fazla görüntünün hizalanmasının ve karşılaştırılmasının gerekli olduğu bilimsel ve endüstriyel uygulamalarda çokça uygulanmaktadır. Bu yöntemler, özünde her görüntüyü tek bir referans görüntüye hizalamak yerine, birden fazla görüntünün birlikte/birarada en iyi hizalanmasını sağlarlar [1, 2, 3, 4]. Oldukça kıymetli olan bu yöntemler, pek çok diğer sahada da geçerli olmakla birlikte, özellikle tıbbi görüntüleme, verilerin karmaşıklığı ve değişkenliğinin yanı sıra, hizalama sürecinin kendine has ideal olmayan karakteristiklerinden dolayı da çeşitli ve de zorlu sorunlarla karşılaşmaktadırlar. Yine tüm sahalarda geçerli olacak şekilde, uygulama çeşitliliklerinin ve de saha sınırlamalarının, kayguların, bütçe, zaman, insan kaynağı farklılıklarının çokluğu nedeniyle tercih edilen yöntemler özelinde de çeşitlilik oluşmaktadır [5]. Yine benzer nedenlerden, tercih edilen geliştirme/yazılım unsurları, programları da kurumların koşullarına bağlı olarak değişmektedirler.

Bildirinin bu ilk bölümünde bahsi geçirilen kritik unsurlar/bileşenler daha detaylı olarak ele alınacaktır. Devamında, grup halinde imge hizalamanın *gürültülü* imgelerde, *hizalama yapılmayan* ve sadece *tek bir imge üzerinden gürültü bastırımı yapılan* sonuçlarla kıyası yapıp, farklı durumlardaki dayanıklılığı görselleştirilecektir.

En nihai sonuç ve tartışma bölümünde ise araştırmalarımız ve yazılım kullanım tecrübelerimiz dahilinde açıklama ve değerlendirmelerimizi yapıp gelecek çalışmalarımızda bize ışık tutacak öngörülerimizi ortaya koyacağız.

¹ Lisans Öğrencisi, Kütahya Sağlık Bilimleri Üniversitesi Bilgisayar Müh., baranalp.ozturk@ksbu.edu.tr

² Dr. Öğretim Üyesi, Kütahya Sağlık Bilimleri Üniversitesi Bilgisayar Müh., ahmet.bastug@ksbu.edu.tr, ORCID iD: <https://orcid.org/0009-0005-9396-8858>

1.1 Kullanım Alanları

Grup halinde görüntü hizalama yöntemleri, bilimsel ve endüstriyel alanlardaki görüntülerin analizlerini, karşılaştırılmalarını ve entegrasyonlarını kolaylaştıran yöntemlerdir. Karar verme, izleme ve optimizasyon amaçlarıyla kullanılabilirler. Bütün bu nedenlerden ve başkaca çokça nedenden dolayı aşağıdaki alanlarda kendisine yer bulmuştur.

1.1.1 Tıbbi Görüntüleme Örnekleri

Görüntü hizalama, tıbbi görüntüleme alanında önemli bir rol oynamaktadır. Hastalıkların teşhisinde, tedavi planlamasında ve hasta takibinde kritik öneme sahiptir. Özellikle, *grup tabanlı* hizalama yöntemleri, çoklu görüntü setlerinin bir arada değerlendirilmesini sağlayarak, hastalıkların daha doğru bir şekilde tanımlanmasına ve izlenmesine olanak tanır. En çok bilinen 3 uygulama alanı aşağıdaki gibidir.

Farklı Kişilerden Alınan Verilere Dayalı Analiz: İstatistiksel analiz ve anatomik farklılıkları anlamak için farklı hastalardan alınan görüntülerin hizalanması ilkesine dayanır [6].

Zamansal Görüntü Dizisi Analizi: Bir hastalığın ilerlemesini, tedavi sonuçlarını ve zaman içinde ortaya çıkan değişiklikleri incelemek için aynı kişiden farklı zamanlarda elde edilen görüntülerin hizalanması ilkesine dayanır [7].

Farklı Sensörlerden Kaynaklı Görüntülerin Füzyonu: Birbirini tamamlayıcı görüntüleme yöntemlerini (MRI, CT, PET,vb) kullanarak teşhisi güçlendirmeye yönelik bir yaklaşımdır [8].

1.1.2 Sinir Bilimi Örnekleri

Beyin Haritalaması: Bu yöntem yapısal ve işlevsel beyin görüntülerinin bireyler arasında hizalanması ilkesine dayanır [9].

Beyin Gelişimi Çalışmaları: Bu yöntem beyin gelişimini incelemek ve nörolojik bozuklukları belirlemek için zaman içinde elde edilen farklı görüntülerin hizalanması ilkesine dayanır [10].

1.1.3 Biyomedikal Araştırma Örnekleri

Onkoloji: Kanser hastalarından alınan tıbbi görüntülerin, örneğin tümör büyümelerinin, hizalanması ilkesine dayanır [11].

Kardiyoloji: Miyokard fonksiyonunu gözlemleyip analiz etmek ve kardiyovasküler hastalıkları incelemek için farklı hastalardan alınan kalp görüntülerinin hizalanması ilkesine dayanır [12].

Ortopedi: Eklemeleri analiz etmek ve ortopedik ameliyatları planlamak için kas ve iskelet sistemi görüntülerinin hizalanması ilkesine dayanır [13].

1.1.4 Bilgisayarla Görme Örnekleri

Uzaktan Algılama: Uydu veya hava görüntülerinin, LIDAR taramalarının hizalanması vesilesiyle arazi sınıflandırması, zamanla ortaya çıkan değişikliklerin tespiti ilkesine dayanır [14].

Robotik: Robotlara monte edilmiş sensörlerden veya kameralardan gelen görüntülerin hizalanması vesilesiyle konumlama, haritalama ve navigasyon ihtiyaçlarını karşılamayı amaçlar [15].

Nesne Tanıma ve İzleme: Nesne tanıma, nesne takibi ve 3 boyutlu gerçekleştirme için sahne görüntülerinin farklı bakış açılarından hizalandırılmaları ilkesine dayanır [16].

Petrol ve Gaz Aramaları: Petrol/gaz kuyularından elde edilen sismik görüntüleri hizalama, yeraltı yapılarını haritalama ve sondaj operasyonlarını planlama için kullanılır [17].

1.1.5 İmalat ve Kalite Kontrol

Bu yöntem üretim süreçlerinde, üretimin farklı aşamalarından elde edilen ürünlerin görüntülerini hizalamak ve analiz etmek için grup bazında görüntü hizalanması ilkesine dayanır. Bir yandan da sağlıklı/referans ürünlerle üretimden elde edilen görüntüleri karşılaştırarak üretilen parçalardaki kusurların, tutarsızlıkların veya sapmaların tespit edilmesini sağlar [18].

1.2 Uygulamadaki Zorluklar

Tıbbi görüntülerin hizalanması bağlamında aşağıda listelenen zorlukların üstesinden gelebilmek için tıbbi görüntüleme, bilgisayarla görme, optimizasyon, makine öğrenimi ve klinik alan bilgisindeki uzmanlığı içeren çok disiplinli bir yaklaşım gerekmektedir.

Popülasyon Değişkenliği: Tıbbi görüntüleme verileri dahilinde genellikle bireyler arasında görüntüleme özelliklerinde önemli farklılıklar gösterir.

Hesap Karmaşıklığı: Grup bazında hizalama kapsamında, birden fazla görüntünün aynı anda hizalanmasını içermesinden dolayı ikili hizalama ile karşılaştırıldığında, hesaplama karmaşıklığı önemli ölçüde artabilir. Bu problem özellikle büyük veriyle çalışıldığında daha da artacaktır.

Çok Modlu Hizalama: Farklı görüntüleme yöntemlerinden (MRI, CT, PET) görüntülerin hizalanması durumunda, görüntülerin pozları, çözünürlükleri ve kontrastlarındaki farklılıklar problem teşkil edecektir.

Doğrusal Olmayan (Nonlinear) Bozulmalar: Tıbbi görüntülerdeki anatomik yapılar karmaşık ve de doğrusal olmayan bozulmalar içerebilir.

1.3 Teknolojinin Güncelinde Öne Çıkan İki Ayrı Yaklaşım

Önceki bölümlerde bahsi geçirilen uygulamaları hayata geçirebilmek ve zorlukların üstesinden gelebilmek adına aşağıda izah edileceği üzere *geleneksel ama oturmuş yöntemler* ile *modern ama yeterince olgunlaşmamış ya da ne yaptıkları çoğu zaman çok iyi anlaşılmayan yapay zeka yöntemleri* kullanılmaktadır.

1.3.1 Konvansiyonel Bilgisayarlı Görü Yöntemleri

Yoğunluğa Dayalı Yöntemler: Hizalandırılan görüntülerdeki karşılık gelen piksellerin ya da voksellerin (3 boyutlu en küçük görüntü parçaları) yoğunluk (intensity) değerleri arasındaki benzerlik metriğinin optimize edilmesine dayanırlar [3].

Özelliğe Dayalı Yöntemler: Hizalama işlemi için görüntülerdeki önemli noktaları veya yer işaretlerini kullanırlar. Kullanılan ortak özellikler arasında köşeler, kenarlar veya diğer ayırt edici görüntü özellikleri bulunur [19].

Optik Akı Yöntemleri: Görüntü özelliklerinin zaman içindeki hareketini izleme ilkesine dayanırlar [20].

Bu en bilinen yöntemlerden ayrı *B-Spline Deformasyonu*, *Serbest Biçimli Deformasyon (FFD)*, *Şablon Tabanlı Yöntemler*, *Karşılıklı Bilgi Maksimizasyonu*, *Çok Ölçekli Hizalama* ve *Grafik Tabanlı Yöntemler* şeklinde daha pek çok konvansiyonel yöntem vardır.

1.3.2 Gelişkin Derin Öğrenme Yöntemleri

Bildirinin ana temasını içermemelerinden dolayı, bu bölümde Gelişkin Derin Öğrenme Yöntemlerinin sadece isimleri listelenecektir [21]: *Evrişimli Sinir Ağları (CNN)*, *Siyam Ağları*, *Üretken Rekabetçi Ağlar (GAN)*, *Uzamsal Transformatör Ağları (STN)*, *Grafik Sinir Ağları (GNN)*, *Tekrarlayan Sinir Ağları (RNN)*.

1.3.3 İki Gruptaki Yöntemlerin Avantaj ve Dezavantajları

Konvansiyonel yöntemler genellikle tanımlı algoritmalara ve elle hazırlanmış özelliklere dayanır ve gerçek zamanlı veya kaynak kısıtlı uygulamalara oldukça uygundurlar. Köklü matematiksel ilkelere ve teorilere dayanmaktadırlar ve de bu durum algoritmaların anlaşılması ve geliştirilmesi için sağlam bir temel oluşturur. Öte yandan genellikle *manuel özellik* çıkarmaları gerektiğinden fazlaca emek gerektirirler. Bir yandan da başarımları büyük ölçüde manuel özelliklerin kalitesine bağlıdır. Bu manuel özellikler sınırlı temsile sebep olduklarından önemli değişkenlik veya karmaşıklık içeren senaryolarda performansları düşebilir; gerçek dünya sahnelerinin karmaşıklığıyla da baş etmekte zorlanabilirler.

Derin Öğrenme yöntemlerine gelecek olursak, manuel özellik mühendisliği ihtiyacı olmadığından *doğrudan ham verilerle* çalışabilirler. Bu uçtan uca öğrenme yaklaşımı, verilerdeki karmaşık kalıpları ve ilişkilerin yakalanmasını sağlayabilir. Derin öğrenme mimarileri esnek ve uyarlanabilir olup, minimum düzeyde değişiklik veya yeniden eğitim ile çok çeşitli bilgisayarlı görme görevlerine uygulanmalarına olanak tanır. Öte yandan, olumsuzluk adına derin öğrenme yöntemleri, yüksek performans elde etmek amacıyla eğitim için genellikle büyük miktarda etiketli veri gerektirir. Etiketli verilerin elde edilmesi pahalı, zaman alıcı veya mümkün olmayabilir. Derin öğrenme modelleri çoğunlukla kapalı sistemler olduklarından, elde ettikleri neticelerin yorumlanması veya açıklanması zor olabilir. Derin öğrenme modellerinin eğitimi, yüksek maliyetli hesaplamalar gerektirebilir ve GPU gibi özel donanımlar gerektirebilirler. Derin öğrenme modelleri, özellikle sınırlı veya gürültülü verilerle eğitildiklerinde datalarla aşırı uyum (overfitting) yapabilirler.

Özetlemek gerekirse, geleneksel ve derin öğrenme yöntemleri arasında yapılacak tercih, etiketli verilerin kullanılabilirliği, hesaplama kaynakları, yorumlanabilirlik gereksinimleri ve eldeki görevin karmaşıklığı gibi faktörlere bağlıdır. *Birinin diğerine üstünlüğünü iddia etmek doğru bir yaklaşım olmaz. Aslında belki de en ideal yaklaşım her ikisinin de peşi sıra bir arada kullanılmasıdır.*

2. Yüksek Gürültülü Medikal Görüntü Gruplarının Konvansiyonel Bir Yöntemle Hizalandırılması

Son yıllarda, tıbbi görüntüleme teknolojilerindeki gelişmeler, görüntü kalitesini ve elde edilen verilerin doğruluğunu önemli ölçüde artırmıştır. Lakin, eski ya da bir nedenden verimliliğini yitirmiş cihazlardan alınan ya da farklı zaman dilimlerinde veya farklı cihazlar tarafından üretilen görüntülerin hizalanması idealden uzak olup zorluklar içerecektir. Bu zorlukların üstesinden gelebilmek için geliştirilen grup tabanlı hizalama yöntemleri, bu görüntüler arasındaki sürekliliği ve tutarlılığı sağlamak amacıyla kritik bir işlev görecektir. MATLAB tarzı ticari yazılımlar veya açık kaynaklı yazılımlar kullanımıyla (örneğin SimpleElastix), bu yöntemlerin uygulanması, çeşitli tıbbi görüntüleme görevlerinde doğruluk ve verimliliği artırma potansiyeline sahiptir.

Bu bölümde ele aldığımız yazılımsal ve algoritmik çalışmanın amacı grup tabanlı hizalama süreçlerinin uygulanabilirliğini, etkinliğini ve tıbbi görüntüleme alanındaki potansiyel katkılarını sistematik bir şekilde incelemektir.

2.1 Yöntem

Yüksek miktarda gürültü içeren ya da ideal olmayan görüntü pozlamasından kaynaklı görüntü kayıplarının olduğu bir imge örneğine sahip olduğunda zaafiyeti gidermek adına aynı görselden çok daha fazla örneğe sahip olmak isteriz. Aynı ayrı incelemelerde her ne kadar birinin eksikliğini diğeri tamamlar noktada olabileceksede de daha iyisi hepsinin hizalanıp eş güdümlü hale getirilmesidir. Sinyal işleme sahasında çok iyi bilindiği üzere bir sinyal unsurundan çokça kopyanın ortalaması alındığında o oranda gürültü varyansı azalır. Lakin bu yalnızca 100% mertebede senkronizasyonun (bizim şu an ele aldığımız mevzuda hizalı olmanın) geçerli olduğu durumlarda doğrudur. Aksi taktirde, ortalama işlemi alındığında tek imgenin sağladığından çok daha kötü bir neticeyle karşı karşıya kalınabilir. Biz bu çalışmada, bu bağlamdaki kazanımları ve sınırlamaları simülasyon çalışmalarıyla gözlemlemek ve görselleştirmek istedik. Çalışmaya başlamadan önceki beklentilerimiz, gürültü varyansının yüksek olduğu veya görüntüler arasındaki *transitional* ya da *rotational* farklılıkların az olduğu durumlarda (simülasyonlarımızda sadece *rotation* kullandık) hizalamadan iyi bir kazanç elde edilebileceği, tersi yönde durumlarda ise kazancın çok azalabileceği ya da kayba dönebileceği noktasındadır.

Simulasyon ve Modelleme mahiyetinde sırasıyla şu aşamalardan oluşan bir yazılım/algortma yapısı kurguladık:

Aşama 1: 8-bit çözünürlüklü gri-tonlu bir medikal imge okuduk.

Aşama 2: İkinci bir imge oluşturma adına daha önceden tanımlanan bir standart sapma ölçeğinde (örneğin $\sigma_n = 32$) ve de sıfır ortalamalı rastgele *Gaussian* gürültü ekledik.

Aşama 3: Şekil 1’de temsil edildiği üzere *Rotational* dönüşümlerle yine daha önceden tanımlı açısız dönme adımları (örneğin $\Delta_\theta = 0.2$ derece) mahiyetinde çokça yeni imge (örneğin, bir durumda 29 ilave görüntü kullandığımızda ilki orijinal imgeye göre 0.2, sonuncusu 5.8 derece dönmüş olacak şekilde) ürettik ve onlara da Aşama 2’de yapıldığı miktarlarda rastgele gürültü ekledik.

Aşama 4: Daha sonra kıyaslama yapma adına (iyi netice vermeyeceğini bilmemize rağmen) 3. aşamada elde edilen tüm görüntülerin ortalamasını alarak hizalanmamış bir imge daha elde ettik.

Aşama 5: Şekil 2’de temsil edildiği üzere Vishnevskiy et.al [22]’de anlatılan algoritmik yaklaşımla uyumlu olarak, 3. aşamada elde edilen çokça görüntünün grup halinde hizalanmasından ve akabinde *hizalanmış tüm imgelerin ortalamasının alınmasından* yeni bir imge daha elde ettik.

Aşama 6: Esaslı/hedef kıyaslamayı yapma adına 2. aşamada elde ettiğimiz gürültülü görüntüyü *Gaussian* filtre (*blurring* işlemi) ile *denoising* işleminden geçirdik ve bir imge daha elde ettik. Bunu yaparken de adil olma adına, denemelerle en ideal *sigma* değerini (σ_f) bulup kullanarak gürültü bastırımı ile keskinlik koruma arasındaki dengeyi oluşturmaya çalıştık.

Bundan sonraki anlatımlarda faydalı olması adına 1. aşama çıktısına *orijinal* imge, 2. aşama çıktısına *gürültülü* imge, 4. aşama çıktısına *ortalama* imge, 5. aşama çıktısına *hizalanmış* imge, 6. aşama çıktısına da *gürültü bastırılmış* imge isimlendirmelerini yapacağız.



Şekil 1 Rotational Dönüşümlerle $\Delta\theta = 0.2$ açısal adımlar



Şekil 2 Grup Halinde Hizalanma (referans görüntü hariç)

2.2 Simulasyon Sonuları



Şekil 3 “Data_Seti_1”, Orijinal İmge.



Şekil 4 “Data_Seti_1”, Gürültülü İmge ($\sigma_n = 32$).



Şekil 5 "Data_Seti_1", 29 İmgenin ($\Delta_{\theta} = 0.1$ derece) Ortalama İmgesi.



Şekil 6 "Data_Seti_1", Gürültü Bastırılmış İmge ($\sigma_f = 2$).



Şekil 7 "Data_Seti_1", 29 İmgenin ($\Delta_{\theta} = 0.1$ derece) Hizalanmış İmgesi.



Şekil 8 "Data_Seti_2"; Orijinal İmge.



Şekil 9 “Data_Seti_2”; Gürültülü İmge ($\sigma_n = 32$).



Şekil 10 “Data_Seti_2”; 29 İmgenin ($\Delta_\theta = 0.1$ derece) Ortalama İmgesi.



Şekil 11 "Data_Seti_2"; Gürültü Bastırılmış İmge ($\sigma_f = 2$).



Şekil 12 "Data_Seti_2"; ($\Delta_{\theta} = 0.1$ derece) Hizalanmış İmgesi.



Şekil 13 "Data_Seti_3"; Sol, Orijinal ve Sağ, Gürültülü İmge ($\sigma_n = 18$).



Şekil 14 "Data_Seti_3"; Sol, Gürültü Bastırılmış İmge ($\sigma_f = 2$);

Sağ, 29 İmgenin ($\Delta_\theta = 0.2$ derece) Hizalanmış İmgesi.



Şekil 15 "Data_Seti_4"; Sol, Orijinal ve Sağ, Gürültülü İmge ($\sigma_n = 10$).



Şekil 16 “Data_Seti_4”; Sol, Gürültü Bastırılmış İmge ($\sigma_f = 2$);
Sağ, 29 İmgenin ($\Delta_\theta = 0.3$ derece) Hizalanmış İmgesi.

Yukarıda 4 ayrı data seti üzerinden elde edilen görsel neticeler paylaşılmıştır. Birinci data setinden *Şekil 3 ila Şekil 7* arasındaki neticeler, ikinci data setinden *Şekil 8 ila Şekil 12* arası neticeler, üçüncü data setinden *Şekil 13 ve Şekil 14*, dördüncü data setinden *de Şekil 15 ve Şekil 16* elde edilmiştir.

İlk iki data setinde (her bir data seti kendi içinde değerlendirilmelidir; bu iki data seti ortak parametrelere sahip oldukları için anlatımları da ortaklaştırılmıştır) *yüksek seviyede* bir gürültü miktarı ($\sigma_n = 32$) ve bir imgeden bir sonraki imgeye (ki bu 29 imge boyunca sürdürülmüştür) *düşük seviyede* bir dönme açısı adımı ($\Delta_\theta = 0.1$ derece) seçilmiştir. Elde ettiğimiz bulgular şu şekildedir:

- Δ_θ açısının azlığından dolayı, tüm imgeler üzerinde işletilen grup temelli hizalama, *Şekil 7'den ve Şekil 12'den* anlaşılacağı üzere oldukça başarılı bir şekilde gerçekleşmiştir. Bu kanaate, imgelerin *keskinliğinin* (sharpness) yüksek olmasından dolayı varıyoruz.
- Bu başarılı hizalama sayesinde ve de her bir girdi imgesi özelindeki σ_n gürültü değeri yüksek tutulduğundan, yine *Şekil 7'den ve Şekil 12'den* anlaşılacağı üzere çıktı imgesinin gürültüsü oldukça iyi bir şekilde *bastırılmıştır*.
- Yine, *Şekil 7 ve Şekil 12* imgelerini *Şekil 5 ve Şekil 10* imgeleriyle kıyasladığımızda *keskinlik* seviyelerinin çok daha iyi olduğu görülmektedir. Burada ortaya çıkan keskinlik farkına *hizalama kazancı* şeklinde yaklaşabiliriz.
- Son olarak, *Şekil 7 ve Şekil 12* imgelerini *Şekil 6 ve Şekil 11* imgeleriyle kıyasladığımızda *gürültü* seviyelerinin çok daha az olduğu görülmektedir. Burada ortaya çıkan gürültü seviyesi farkına *gürültü bastırma kazancı* şeklinde yaklaşabiliriz. Burada vurgu yapmamız gereken konu; *Şekil 7 ve Şekil 12'de* doğaları gereği (daha önce de bahsedildiği üzere bir sinyal/görüntü unsurundan çokça kopyanın *ortalaması* alındığında, *sinyal/görüntü sayısı oranında* gürültü varyansı azalır), *implicit* (örtülü) bir şekilde gürültünün bastırıldığıdır. Burada yapılan gürültü bastırma işlemi aslında bir *temporal filtering* (zamanda filtreleme) işlemi olmaktadır. Kıyaslamada kullanılan *Şekil 6 ve Şekil 11'deki* elde edilen neticeler ise *explicit* (açık) bir şekilde yapılan *spatial filtering* (uzaysal filtreleme) gürültü giderme işlemidir. Lakin bu *en yüksek* gürültü bastırma kazancı, hizalamanın mükemmel olduğu durumlarda geçerli olacak olup, kazanç miktarı *hizalamadaki kayma miktarıyla* ve de *imgelerin sahip oldukları frekans bileşenlerinin yüksekliği ölçeğinde* azalabilecektir. En temel amaç gürültü bastırmak olduğunda, en ideal yaklaşım hem *spatial* hem de *temporal* filtrelemeyi bir arada kullanan yaklaşımlar türetmektir. Bu bağlamda da çokça farklı

yaklaşım benimsenebilir. Görüntüleri önce *spatial* filtreden geçirip sonrasında *temporal filtering* (hizalama sonrası zamansal ortalama) işleminden geçirmek bir yaklaşım olabilir. Bu işlemlerin sırasını tersine çevirmek bir başka alternatif yaklaşım olabilir. Daha ideali ise, bu işlemleri *spatiotemporal filtering* dahilinde birarada (*jointly*) yapmak olacaktır. En gelişkinlik adına da ilave bir katkı olarak RANSAC (Random Sample Consensus) kullanımıyla, görüntü dizisi içerisinde hizalamada uyumsuzluk oluşturanları devre dışı bırakmak akılcı bir yaklaşım olacaktır.

Üçüncü data setinde *orta seviyede* bir gürültü miktarı ($\sigma_n = 18$) ve bir imgeden bir sonraki imgeye (ki bu 29 imge boyunca sürdürülmüştür) yine *orta seviyede* bir dönme açısı adımı ($\Delta_\theta = 0.2$ derece) seçilmiştir. Her iki unsur da ele aldığımız hizalama yönteminin başarımı için gerekli ideal koşullardan bir miktar uzaklaştırılmış olduğundan, haliyle, *Şekil 14'den* de anlaşılacağı üzere, hizalama başarımları az seviyede oluşmuştur. *Spatial filtering* (uzamsal filtreleme) gürültü giderme işlemi ile kıyasladığımızda *gürültü performansı* bağlamında çok az geride kalmakla birlikte *keskinlik performansı* mahiyetinde hala oldukça daha iyi noktadadır. Lakin yavaş yavaş da olsa, hizalama kusurlarından kaynaklı yapısal kusurlar (*artifact*) ortaya çıkmaya başlamaktadır. Bu ara seviyeler bir nevi grup temelli hizalama yaklaşımının *kırılma* seviyeleridir.

Son olarak, dördüncü data setinde, *daha da azaltılmış seviyede* bir gürültü miktarı ($\sigma_n = 10$) ve *bir miktar daha artırılmış seviyede* bir dönme açısı adımı ($\Delta_\theta = 0.3$ derece) seçilmiştir. Her iki unsur da ele aldığımız hizalama yönteminin başarımı için gerekli ideal koşullardan oldukça fazla uzaklaştırılmış olduğundan, beklendiği üzere ve de *Şekil 16'dan* da anlaşılacağı üzere, hizalama başarımı artık düştüğü görülebilir noktadadır. *Spatial filtering* (uzamsal filtreleme) gürültü giderme işlemi ile kıyasladığımızda, *gürültü performansı* bağlamında da, *keskinlik performansı* mahiyetinde de çok daha kötü noktada olup hizalama kusurlarından kaynaklı yapısal kusurlar da (*artifact*) iyice ortaya çıkmış, fazlaca kopma ve kırılmalar olmuştur.

3. Sonuç ve Tartışma

Bu bildiride önce grup halinde görüntü hizalama konusunun alt yapısını oluşturduktan sonra yaptığımız yazılımsal ve algoritmik çalışmaları ve sonuçlarını sunduk. Konvansiyonel yaklaşımlar kapsamında ele alınan bu örnekler ve benzeri çalışmalar daha da gelişkin derin öğrenme tarzı çalışmalara ön zemin hazırlama (preprocessing) mahiyetinde kullanılacak yöntemler olarak da görülebilir.

Derin öğrenme her ne kadar iyi uygulandığında state-of-the-art mahiyetinde rol sergileyebilecek olsa da kapalı, yaptıkları çok iyi anlaşılıp yorumlanamayan bir yanı olmasından dolayı ve de çoğu zaman çok pahalıya gelebilecek şekilde ve de data toplama esnasında zaman gerektirecek şekilde meşakkatli olacağından; zorlukları fazla, pek çok vakit kullanılmayacak bir yaklaşım olacaktır. Aslında her bilgisayarlı görüntü çalışmasının, hele ki yapay sinir ağları içeren derin öğrenme yönteminin, daha kararlı ve başarılı olmasını sağlayacak çokça ön data işleme fazları vardır. Bir yapay sinir ağları içeren ve grup temelli görüntü hizalama yapan derin öğrenme yönteminin kullanabileceği ön faz işlemler arasında görüntülerin gürültülerini azaltma/bastırma, histogram eşitleme, görüntüleri kesme/kırpma ve veriler üzerinde yapılabilecek veri büyütme (data augmentation), veri dengeleme gibi işlemler olabileceği gibi bu çalışmada örnekleri gösterildiği gibi bizzat bir konvansiyonel grup temelli görüntü hizalama işlemi de bir nevi işi önden kabaca kotararak derin öğrenme yönteminin ortaya koyması gereken eforu ve data ihtiyacını ya da model karmaşıklığını azaltacaktır. Bir başka faydası da konvansiyonel yaklaşımlarla bir nevi daha bir saha hakimiyeti olacağından akabindeki derin öğrenme yönteminin de neler yapabileceği konusunda daha az belirsizlik olacaktır.

Bu bildiri, bir nevi, grup bazında görüntü hizalama yöntemlerinin gereksinimlerini ve zorluklarını anlamaya yönelik ve de gelişkin derin öğrenme yöntemlerine başlamadan önce konvansiyonel yöntemleri iyi anlamak ve uygulamaya yönelik yazılım çalışmalarını ihtiva eder olmuştur. Gelecek çalışmalar mahiyetinde önce bu çalışmaları daha da olgunlaştırıp daha sonra da bu çalışmaları derin öğrenme yöntemlerine taşımak amaçladıklarımız arasındadır. Bir başka üzerine eğilmeyi düşündüğümüz mevzu da verilerin toplandığı kamera, sensör ya da başkaca görüntüleme teknolojilerinde -çalışmalarımız sadece medikal sahaya sınırlı değildir- çokça kaynaktan alınan görüntülerin/datanın en sağlıklı olarak ne şekilde *birarada alınabileceği* konusudur. Literatürde çokça kameradan ya da bir kameradan çokça farklı zamanlarda alınan görüntülerin kaynağında ya da da kaynaklarında en sağlıklı şekillerde alınabilmeleri (*acquisition*), içsel ve dışsal kamera parametrelerinin (*intrinsic ve extrinsic*) daha iyi kestirilebilmeleri kamera sistemleri özelinde “bundle adjustment” adı altında ayrı bir konuyu oluşturmaktadır [23]. Bundle adjustment ve grup temelli görüntü hizalama biraraya getirildiğinde kaynağında görüntülerin en sağlıklı şekilde bir arada üretilmelerinden, sonrasında bir arada değerlendirilebilmelerine kadar tüm zincirde verimliliği en üst düzeye çıkarmak amaçlanabilir. Oldukça sofistike sistemsel yaklaşımlar ihtiva edecek

olmalarına rağmen, bu tarz yaklaşımlar ileriki yıllarda yapmayı düşünebileceğimiz çalışmalar için bize ışık tutar noktadadır.

Anahtar Kelimeler: Grup bazında görüntü hizalama; medikal görüntü analizi; zaman görüntü dizisi analizi; multimodal görüntü füzyonu.

KAYNAKÇA

1. A. Bartoli, "Groupwise Geometric and Photometric Direct Image Registration," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, no. 12, pp. 2098-2108, Dec. 2008
2. Huizinga, W., Poot, D. H., Guyader, J. M., Klaassen, R., Coolen, B. F., van Kranenburg, M., ... & Klein, S. (2016). PCA-based groupwise image registration for quantitative MRI. *Medical image analysis*, 29, 65-78.
3. Wu, G., Jia, H., Wang, Q., & Shen, D. (2011). SharpMean: groupwise registration guided by sharp mean image and tree-based registration. *NeuroImage*, 56(4), 1968-1981.
4. Geng, X., Christensen, G. E., Gu, H., Ross, T. J., & Yang, Y. (2009). Implicit reference-based group-wise image registration and its application to structural and functional MRI. *Neuroimage*, 47(4), 1341-1351.
5. Alam, F., Rahman, S. U., Din, A. U., & Qayum, F. (2018). Medical image registration: Classification, applications and issues. *JPMI*, 32(4), 300.
6. Hu, Y., Gibson, E., Ahmed, H. U., Moore, C. M., Emberton, M., & Barratt, D. C. (2015). Population-based prediction of subject-specific prostate deformation for MR-to-ultrasound image registration. *Medical image analysis*, 26(1), 332-344.
7. Cazoulat, G., Owen, D., Matuszak, M. M., Balter, J. M., & Brock, K. K. (2016). Biomechanical deformable image registration of longitudinal lung CT images using vessel information. *Physics in Medicine & Biology*, 61(13), 4826.
8. Slomka, P. J., & Baum, R. P. (2009). Multimodality image registration with software: state-of-the-art. *European journal of nuclear medicine and molecular imaging*, 36, 44-55.
9. Toga, A. W., & Thompson, P. M. (2001). The role of image registration in brain mapping. *Image and vision computing*, 19(1-2), 3-24.
10. Gholipour, A., Kehtarnavaz, N., Briggs, R., Devous, M., & Gopinath, K. (2007). Brain functional localization: a survey of image registration techniques. *IEEE transactions on medical imaging*, 26(4), 427-451.
11. Oh, S., & Kim, S. (2017). Deformable image registration in radiation therapy. *Radiation oncology journal*, 35(2), 101.
12. Makela, T., Clarysse, P., Sipila, O., Pauna, N., Pham, Q. C., Katila, T., & Magnin, I. E. (2002). A review of cardiac image registration methods. *IEEE Transactions on medical imaging*, 21(9), 1011-1021.
13. Ma, B., & Ellis, R. E. (2003). Robust registration for computer-integrated orthopedic surgery: laboratory validation and clinical experience. *Medical image analysis*, 7(3), 237-250.
14. Yang, K., Pan, A., Yang, Y., Zhang, S., Ong, S. H., & Tang, H. (2017). Remote sensing image registration using multiple image features. *Remote Sensing*, 9(6), 581.
15. Pomerleau, F., Colas, F., & Siegwart, R. (2015). A review of point cloud registration algorithms for mobile robotics. *Foundations and Trends® in Robotics*, 4(1), 1-104.
16. Uenohara, M., & Kanade, T. (1995). Vision-based object registration for real-time image overlay. *Computers in Biology and Medicine*, 25(2), 249-260.

17. Fomel, S., Backus, M. M., DeAngelo, M. V., Murray, P. E., & Hardage, B. A. (2003, May). Multicomponent seismic data registration for subsurface characterization in the shallow Gulf of Mexico. In *Offshore Technology Conference* (pp. OTC-15117). OTC.
18. Li, T., Pan, Q., Gao, L., & Li, P. (2017). Differential evolution algorithm-based range image registration for free-form surface parts quality inspection. *Swarm and Evolutionary Computation*, *36*, 106-123.
19. Wu, G., Wang, Q., Jia, H., & Shen, D. (2012). Feature-based groupwise registration by hierarchical anatomical correspondence detection. *Human brain mapping*, *33*(2), 253-271.
20. Yang, D., Li, H., Low, D. A., Deasy, J. O., & El Naqa, I. (2008). A fast inverse consistent deformable image registration method based on symmetric optical flow computation. *Physics in Medicine & Biology*, *53*(21), 6143.
21. Haskins, G., Kruger, U., & Yan, P. (2020). Deep learning in medical image registration: a survey. *Machine Vision and Applications*, *31*(1), 8.
22. Vishnevskiy, Valery, Tobias Gass, Gabor Szekely, Christine Tanner, and Orcun Goksel. "Isotropic Total Variation Regularization of Displacements in Parametric Image Registration." *IEEE Transactions on Medical Imaging* *36*, no. 2 (February 2017): 385–95. <https://doi.org/10.1109/TMI.2016.2610583>.
23. Konolige, K., & Agrawal, M. (2008). FrameSLAM: From bundle adjustment to real-time visual mapping. *IEEE Transactions on Robotics*, *24*(5), 1066-1077.

Alkolsüz Yađlı Karaciđer Hastalıđı Tanısında Yapay Zekâ

Hatice Kbra TAŐDEMİR¹, Gll KAYMAK¹, Elif AYDIN¹, AyŐe KOŐAK SEZGİN¹,
Meliha KOLDEMİR GNDZ¹

zet

Alkolsz yađlı karaciđer hastalıđı (NAFLD), dnya apında hızla artan insidansa sahip, yaygın bir karaciđer hastalıđıdır. NAFLD metabolik sendromla iliŐkilidir ve obezite prevalansının artmasıyla birlikte hızla artmaktadır. Tıp bilimi ok geliŐmiŐ olmasına rađmen, NAFLD'nin teŐhisi ve tedavisi birok zorlukla karŐı karŐıyadır. Yapay zekâ (AI), insan zekâsını simle etmek ve geniŐletmek iin bilgisayar programlarının kullanımını ifade eder ve hastalıkların tanı ve tedavisinde uygulama olanaklarına sahiptir. AI teknolojisini geleneksel invaziv (karaciđer biyopsisi) ve invazif olmayan (geici elastografi, serum biyobelirteleri veya klinik tahmin modelleri) yaklaŐımların stne uygulamanın birden fazla yolu vardır. Bu derleme, yakın zamanda yayınlanan NAFLD alanında yapay zeka ile ilgili araŐtırmaları gzden geirerek, elektronik sađlık kaydı ve laboratuvar testi, ultrason ve radyo grntleme ve karaciđer histopatolojik verilerine dayalı teŐhis modellerini zetlemektedir.

Anahtar Kelimeler: Alkolsz yađlı karaciđer hastalıđı; makine đrenimi; yapay zekâ

¹Ktahya Sađlık Bilimleri niversitesi, Tıp Fakltesi

Artificial Intelligence In Clinic Microbiology Laboratories

Dicle AYDIN¹, Ayşe KOÇAK SEZGİN¹, Güllü KAYMAK¹, Meliha KOLDEMİR¹
GÜNDÜZ⁴, Elif AYDIN¹

Abstract

In developing countries, infectious diseases continue to be a threat to the general public. An accurate diagnosis is essential for both patient and public health treatment to be effective. It takes expertise and discretion to interpret the findings of semi-quantitative or qualitative microbiological examinations. Daily laboratory procedures are incorporating artificial intelligence algorithms, which are used to evaluate data in our daily lives. Applications of artificial intelligence in clinical microbiology laboratories are starting to provide real or potential benefits. Hence, microorganisms identification has been achieved by artificial intelligence. The purpose of this paper is to examine how artificial intelligence is currently applied in clinical microbiology. The data used for this compilation were from searches conducted in April 2024, Google Scholar, and PubMed. These 1. days, it is possible to automatically evaluate some species of bacterial cultures through the use of laboratory automation tools. The ability to autonomously interpret blood, Gaita emissions, and Gram stains has been made possible by developments in computer vision and Lam scanning technologies. It is anticipated that closer cooperation between humans and machines would enhance patient care in the future. In order to guarantee the best efficiency and quality in clinical microbiology laboratory applications, computers and clinical laboratory scientists will collaborate more closely. It is also anticipated that these technologies will be used more broadly by modifying the physical facilities and staffing of laboratories to accommodate automation and artificial intelligence.

Keywords: Artificial Intelligence, microbiology laboratories

¹Kütahya Sağlık Bilimleri Üniversitesi, Tıp Fakültesi

REFERENCES

1. Smith, K. (2024). Artificial intelligence in clinical microbiology. In *Artificial Intelligence in Clinical Practice* (pp. 47-50). Academic Press.
2. Marletta, S., L'Imperio, V., Eccher, A., Antonini, P., Santonico, N., Girolami, I., ... & Pantanowitz, L. (2023). Artificial intelligence-based tools applied to pathological diagnosis of microbiological diseases. *Pathology-Research and Practice*, 243, 154362.
3. Mencacci, A., De Socio, G. V., Pirelli, E., Bondi, P., & Cenci, E. (2023). Laboratory Automation, Informatics and Artificial Intelligence: current and future perspectives in clinical microbiology. *Frontiers in Cellular and Infection Microbiology*, 13, 1188684.
4. Rawson, T. M., Peiffer-Smadja, N., & Holmes, A. (2020). Artificial intelligence in infectious diseases. *Artificial Intelligence in Medicine*, 1- 14.

Sürekli Diyabet Takip Sistemi: Cgm Cihazı

Zeynep ALTIN¹, Ahmet ATLI², Sena ÖZATA³, Hanife Eslem SEMİR⁴, Songül ALPFİDAN⁵, Ahmet Furkan KARATAŞ⁶

Özet

Diyabet, vücudun birey için var olan insülini gerektiği gibi kullanamaması ya da ihtiyaç duyulan insülini yeteri kadar üretememesi ile oluşan bir metabolik bozukluktur. CGM cihazı diyabetli bireyler için özel geliştirilmiş yapay zekâ uygulama tabanlı bir uygulamadır. Bu teknoloji “cilt altı glikoz takip sensörü” olarak da isimlendirilen ve kimi zamanlar kullanıcılar arasında “İnsülin Pompası” olarak da nitelendirilen sensörlü öz-takip cihazıdır. Gerçek zamanlı SĞİ cihazları, parmaktan ölçümle kan şekeri izleminden farklı olarak, değişim hızını gösteren oklarla kan şekeri değişiminin yönü ve şiddeti, mevcut kan şekeri seviyesi gibi konularda bilgi sağlamaktadır. CGM Cihazını Tip 1 diyabet hastaları, kan glikoz seviyesinde dalgalanma olan bireyler, hipoglisemi bilincinde olmayan bireyler, küçük yaştaki çocuklar ve ergenler kullanabilmektedir. Slovenya’da gerçekleştirilen bir araştırmada, okul öncesi dönemdeki çocuklarda SĞİ (CGM) kullanımının kan şekeri dalgalanmasını da düşürdüğü saptanmıştır. CGM cihazlarının avantajları; hipoglisemi korkusunda belirgin düşme, ebeveynlerin uyku kalitesinde önemli yükseliş, hipoglisemi duyarsızlığında düşme, HbA1c de orantılı düşüş (%8,4’den %8,1’e) olarak sıralanabilir. Dezavantajları ise cilt problemleri (skar oluşumu, kaşıntı, ödem), fiziksel görünüş (robotik hissetme, diğerlerinden farklı hissetme, teknik zorluk ve olası kanamalarıdır. CGM cihazını kullanırken dikkat edilmesi gereken bir takım önemli durumlar bulunmaktadır. Bunlar; aktiviteler sonucunda beklenmedik şekilde sensörün çıkmasını önlemek için ek yapışkan ürünlerin kullanılması, sensör yerleştirme bölgelerinde cilt

¹ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, zeynep.altin@ogr.ksbu.edu.tr

² Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, ahmet.atli@ogr.ksbu.edu.tr

³ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, sena.ozata@ogr.ksbu.edu.tr

⁴ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, heslem.semir@ogr.ksbu.edu.tr

⁵ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, songul.alpfidan@ogr.ksbu.edu.tr

⁶ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, afurkan.karatas@ogr.ksbu.edu.tr

tahrişlerini önlemek amacıyla tropikal bakım veya bariyer bantları kullanılması, hijyen gereksinimlerine dikkat edilmesi olarak sıralanabilir.

Anahtar Kelimeler: Diyabet; İnsülin; Kan şekeri.

KAYNAKÇA

1. Çilingirođlu EN. Sürekli glukoz izlemi cihazlarının kullanımında sık karşılaşılan sorunlar.
2. Erten A. Tip 2 diyabet hastalarının diyabetin komplikasyonları ile ilgili bilgi düzeyleri ve glisemik kontrolle ilişkisi. 2022.
3. Hatun Ş, Deyneli O, Mutlu GY. Sürekli glukoz izleminin etkin kullanımı. Diyabetli Çocuklar Vakfı Yayınları. 2020. ISBN: 978-605-83864-4-0
4. Heinemann, Lutz et al. "Glucose measurement and control in patients with type 1 or type 2 diabetes." Experimental and clinical endocrinology & diabetes : official journal, German Society of Endocrinology [and] German Diabetes Association. 2019;127(01): 8-26. doi:10.1055/a-1018-9090
5. Kısaç N, Amp Rashidi M. Diyabetli bireylerin öz yönetim algısına diyabet eğitiminin etkisi. Euroasia Journal of Mathematics, Engineering, Natural & Amp; Medical Sciences. 2023;10(31): 12-18.
6. Melike Ş, Gülşah B. Sosyo-biyo-teknik bakım kompleksi: Tip 1 diyabette dijital sağlık takibi. Sosyoloji Araştırmaları Dergisi. 2020;(110-145): 112-113.

Meryem ARSLAN¹, Damla KAYDI², Merve AYDOĞDU³

Özet

Giyilebilir teknolojiler, vücuda yerleştirilebilen, aksesuar veya elbiselerin içine takılarak taşınabilen bütün elektronik cihazlar şeklinde adlandırılmaktadır. Kullanımı kolay, fonksiyonel uyum sağlayan bireylerin hareketlerini kısıtlamayan, mahremiyet açısından sorun oluşturmayan araçlar olarak tasarlanmıştır. Hastaların durumunun hastane dışında da takip edilebilmesi, hastanede kalış süresinin kısaltılması, sağlık kayıtları açısından veri tabanı oluşturması, sağlık hizmetinin maliyetini azaltması, zamandan tasarruf sağlama giyilebilir teknolojilerin yararları olarak sıralanabilir. Literatürde; glikoz ter algılama cihazı, akıllı kontak lens, glikoz tükürük algılama cihazı, akıllı dövmeleler, podimetric smartmat, Pedar-X, hareket sensörü, giyilebilir sensör sistemleri gibi inovatif uygulamalar bulunmaktadır. Teknolojinin gelişmesi diyabet hemşireliği girişimlerinde bakımı iyileştirmek için yeni imkanlar ortaya koymaktadır. Gelişen dünya ve inovatif ilerlemelerle sağlık hizmetlerinin daha uzun vadeli bir biçime bürüneceği beklenilmektedir.

Anahtar Kelimeler: Diyabet; Hemşire; Yapay zeka.

Kaynaklar

1. Bandođkar AJ, Wang J. Non-invasive wearable electro chemical sensors:are view.Trends in Biotechnology [online]. 2014; 32 (7), 363-371. URL:<https://www.sciencedirect.com/science/article/abs/pii/S0167779914000699>.
2. Bennett MG, Naranja Jr RJ. Getting nano tattoos right-a checklist of legal and ethical hurdles for an emerging nanomedical technology. Nanomedicine:Nanotechnology, Biology and Medicine. 2013;9(6): 729-731.
3. Brognara L, Mazzotti A, DiMartino A, Faldini C, Cauli O. Wearable sensor for assessing gaitand postural alterations in patients with diabetes: A scoping review. Medicina (Kaunas). 2021;57(11):1145.

¹ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, meryem.arslan@ogr.ksbu.edu.tr

² Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, damla.kaydi@ogr.ksbu.edu.tr

³ Öğrenci hemşire, Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Kütahya, Türkiye, merve.aydogdu@ogr.ksbu.edu.tr

4. Bus SA. Innovations in plantar pressure and foot temperature measurements in diabetes. *Diabetes Metab Res Rev.* 2016;32 Suppl 1:221-226. doi:10.1002/dmrr.2760.23Nisan 2024
5. Frykberg RG, Gordon IL, Reyzelman AM, et al. Feasibility and Efficacy of a Smart Mat Technology to Predict Development of Diabetic Plantar Ulcers. *Diabetes Care.* 2017;40(7):973-980. doi:10.2337/dc16-2294.
6. Gao W, Emaminejad S, Nyein H, Challa S, Chen K, Peck A et al. Fully integrated Mwearable sensor arrays for multiplexed in situ perspiration analysis. *Nature* [online].2016; 529 (7587): 509-514. URL: <https://pubmed.ncbi.nlm.nih.gov/26819044/>.
7. Heo, Y. J., & Takeuchi, S. (2013). Toward smart tattoos: implantable biosensors for continuous glucose monitoring. *Advanced Healthcare Materials*, 2(1), 43-56.
8. Kume, EM (2012). Akıllı dövmeler: sürekli glikoz takibinde bir yenilik. Erişim: <http://utdr.utoledo.edu/cgi/viewcontent.cgi>.
9. Lazzarini PA, Crews RT, van Netten JJ, et al. Measuring plantar tissue stress in people with diabetic peripheral neuropathy: A critical concept in diabetic foot management. *J Diabetes Sci Technol.* 2019;13(5):869-880. doi:10.1177/1932296819849092.
10. Matchar E. This tiny tooth sensor could keep track of the food you eat. URL: <https://www.smithsonianmag.com/innovation/this-tiny-tooth-sensor-could-keep-track-food-you-eat-180968763/>.
11. Necefi B, Ron E, Enriquez A, Marin I, Razjouyan J, Armstrong DG. Daha akıllı taban sağkalımı: Ülserasyon riski yüksek olan nöropatik hastalar akıllı iç taban tabanlı ayak koruma sistemi kullanacak mı? *Diyabet Bilimi ve Teknolojisi Dergisi.* 2017;11(4): 702-713.
12. Woldaregay AZ, Årsand E, Walderhaug S, Albers D, Mamykina L, Botsis T, Hartvigsen G. Data-driven modeling and prediction of blood glucose dynamics: Machine learning applications in type 1 diabetes. *Artif Intell Med.* 2019;98: 109-134.

Diyabetin Öz Yönetiminde Beslenme Ve Fiziksel Aktivite Davranışlarını Destekleyen E-Sağlık Teknolojileri

Saliha ÇOKDİNÇER

Özet

Günümüz sağlık dünyası mevcut rahatsızlıkların tedavilerinde gelenekselleşmiş tedavi yöntemlerinin yanı sıra bu tedavilere teknolojiyi de entegre ederek tedavi maliyetlerini düşürmeyi ve tedaviler için harcanan enerjiyi minimuma indirmeyi amaçlamaktadır. Diyabet, genel olarak sağlık profesyonellerinin bildiği üzere; yaşam düzenini bir bütün olarak etkilemekte ve dolayısıyla diyabet hastalarının bu hastalığı idame edebilmeleri için hastalara yüksek motivasyon ve yaşam enerjisi gerekli olurken sağlık çalışanlarına ve sağlık sistemlerine yüksek maliyet ve enerji kaybı olarak geri dönmektedir. Modernleşen sağlık dünyası, diyabetin sağlık sistemlerine ve diyabet hastalarının üzerine bindirdiği yükü hafifletebilmek amacıyla hastaların iradesini ve öz yönetimini destekleyebilecek sistemleri geliştirme yolunda ilerlemektedir. Diyabetli bireylerin öz yönetimlerini eğitmek amaçlı yapılmış uygulamalardan faydalanabilmeleri için dijital okuryazarlığa sahip olmalı ve dijital sağlığın kullanışı konusunda motivasyona sahip olması gerekmektedir. Tam da bu noktada işin içine sağlık profesyonelleri girmekte ve biz hemşireler hastalara diyabet ve teknoloji uyumu noktasında koçluk görevi üstlenmeliyiz.

Anahtar Kelimeler: Beslenme, Diyabet, e-sağlık, Fiziksel aktivite, Öz yönetim.

KAYNAKÇA

1. Adlı GD. Diyabet özyönetim eğitimi ve desteğinde tele sağlık teknolojileri ve hemşirenin rolü. *Gevher Nesibe Journal Of Medical and Healthy Sciences*. 2023;8(1): 142-151.
2. American Diabetes Association. 3. Foundations of care and comprehensive medical evaluation. *Diabetes Care*. 2016;9(suppl 1): 23-35.
3. Anthimopoulos M, Dehais J, Shevchik S, Ransford BH, Duke D, Diem P, et al. Computer vision-based carbohydrate estimation for type 1 patients with diabetes using smartphones. *Journal of Diabetes Science and Technology*. 2015;9(3): 507-515.
4. Årsand E, Muzny M, Bradway M, Muzik J, Hartvigsen G. Performance of the first combined smartwatch and smartphone diabetes diary application study. *Journal of Diabetes Science and Technology*. 2015;9(3): 556-563.

5. Baskerville R, Ricci-Cabello I, Roberts N, Farmer A. Impact of accelerometer and pedometer use on physical activity and glycaemic control in people with Type 2 diabetes: A systematic review and meta-analysis. *Diabetic Medicine: A Journal of the British Diabetic Association*. 2017;34(5): 612–620.
6. Büyükkaya Besen D, Dervişoğlu M. Diyabet yönetiminde teknoloji kullanımı. *Türkiye Klinikleri Journal of Internal Medicine*. 2021;6(2).
7. El-Gayar O, Timsina P, Nawar N, Eid W. A systematic review of IT for diabetes self-management: Are we there yet?. *International Journal of Medical Informatics*. 2013;82(8): 637–652.
8. Greenwood DA, Gee PM, Fatkin KJ, Peeples M. A systematic review of reviews evaluating technology enabled diabetes self-management education and support. *Journal of Diabetes Science and Technology*. 2017;11(5): 1015–1027.
9. Güneş M, Demirer B. Diyabetin öz yönetiminde beslenme ve fiziksel aktivite davranışlarını destekleyen e-sağlık teknolojileri: Bir derleme (E-health technologies supporting nutrition and physical activity behaviors in diabetes self-management: A. Full Text Book, 70; 2020.
10. Idris MY, Alema-Mensah E, Olorundare E, Mohammad M, Brown M, Ofili E, Pemu P. Exploring the discursive emphasis on patients and coaches who participated in technology-assisted diabetes self-management education: Clinical implementation study of health. *Journal of Medical Internet Research*. 2022;24(3): e23535. [doi:10.2196/23535](https://doi.org/10.2196/23535)
11. Pereira K, Phillips B, Johnson C, Vorderstrasse A. Internet delivered diabetes self-management education: A review. *Diabetes Technology Therapeutics*. 2015;17(1): 55–63.
12. Qiu S, Cai X, Chen X, Yang B, Sun Z. Step counter use in type 2 diabetes: A meta-analysis of randomized controlled trials. *BMC Medicine*. 2014;12: 36.
13. Reeder B, David A. Health at hand: A systematic review of smart watch uses for health and wellness. *Journal of Biomedical Informatics*. 2016;63: 269–276.
14. Rosal MC, Heyden R, Mejilla R, Rizzo Depaoli M, Veerappa C, Wiecha JM. Design and methods for a comparative effectiveness pilot study: Virtual world vs. face-to-face diabetes self-management. *JMIR Research Protocols*. 2012;1(2): 24.
15. Shan R, Sarkar S, Martin SS. Digital health technology and mobile devices for the management of diabetes mellitus: State of the art. *Diabetologia*. 2019;62(6): 877–887. [doi:10.1007/s00125-019-4864-7](https://doi.org/10.1007/s00125-019-4864-7)
16. Waki K, Aizawa K, Kato S, Fujita H, Lee H, Kobayashi H, et al. Diabetics with a multimedia food recording tool, foodlog: Smartphone-based self-management for type 2 diabetes. *Journal of Diabetes Science and Technology*. 2015;9(3): 534–540.

Özet

Giriş ve Amaç: Postpartum dönemde etkili ve başarılı bir emzirmenin gerçekleşmesi hem maternal hem de fetal sağlık düzeyi açısından önemli bir rol oynamaktadır. Emzirme sürecinin postpartum dönemde etkili ve başarılı bir şekilde gerçekleşmesinde sağlık profesyonellerinin rolü çok önemli olsa da bu süreçte yenilikçi yöntemlerin kullanılmasının emzirme başarısını ve etkinliğini arttırmada etkili olduğuna dair kanıtlar mevcuttur. Bu yenilikçi yöntemlerden biri de emzirme sürecinde sanal gerçeklik kullanımınıdır. Sanal gerçeklik ile emzirme sürecini geliştirmek için yapılan girişimler hem daha eğlenceli hale gelmekte hem de postpartum dönemdeki kadınların ilgisini çekerek kadınlara daha hızlı bilgi edinme ve anında düşünme fırsatı sunmaktadır. Bu derleme çalışması literatür incelemesi yoluyla postpartum dönemdeki annelerin emzirme sürecinde sanal gerçeklik kullanımının emzirme sürecindeki etkilerini irdelenmek amacıyla yapılmıştır.

Yöntem: Bu derleme literatüre dayanarak yapılmış ve bu bağlamda; Google Akademik, EbscoHost, Pubmed ve Science Direct veri tabanlarının taranması yoluyla yapılmıştır.

Sonuç ve Öneriler: Konuya ilişkin kısıtlı sayıda çalışmaya rastlansa da postpartum dönemde sanal gerçeklik kullanımının emzirme sürecinde olumlu etkileri olduğu yönünde kanıtlarla karşılaşılmıştır. Bu bağlamda konuya ilişkin çalışmaların artırılması ve sağlık profesyonellerinin postpartum emzirme başarısının artması noktasında sanal gerçeklik konusuna eğilmeleri önerilebilir.

Anahtar Kelimeler: Postpartum, emzirme, sanal gerçeklik

0-6 Yaş Grubu Çocuklarda Dijital Bağımlılık Ve Ebeğin Rolü

Zeynep FİDAN AYGIRGÖL

ÖZET

Giriş ve Amaç: Ebelik; bilim ve sanatı birleştiren, bilimsel ve etik değerler üzerine temellenmiş bir meslektir. Ebeler, kadın sağlığına ilişkin girişimlerin yanı sıra koruyucu önlemler almak, kadın, aile ve topluma antenatal dönem, ana-babalığa hazırlık, kadın sağlığı, üreme ve cinsel sağlık ve çocuk-bebek bakımı konularında danışmanlık ve eğitim yapmakla yükümlüdür. Teknolojinin gelişmesiyle birlikte her eve giren internet ve teknolojik ürünler ebeveynlerin doğumdan itibaren çocuk yetiştirmedeki rollerinde yer edinmiştir. Tüm bu teknolojinin içinde büyüyen çocuklarda dijital bağımlılık giderek artış göstermektedir. Bu çalışma 0-6 yaş grubu çocukların dijital bağımlılık ve bu bağımlılığı etkileyen faktörleri literatür aracılığıyla irdelemek amacıyla yapılmıştır.

Yöntem: Bu derleme literatüre dayanarak yapılmış ve bu bağlamda; Google Akademik, EbscoHost, Pubmed ve Science Direct veri tabanlarının taranması yoluyla yapılmıştır.

Sonuç ve Öneriler: Literatür incelendiğinde çocukların beslenme gibi temel ihtiyaçlarını karşılarken bile dijital ortamdaki ayrılımlarının giderek zorlaştığını ve dijital bağımlılığın artış gösterdiğini, dijital video oyunları gibi unsurlara bağımlılık geliştirdiklerini göstermiştir. 0-6 yaş grubu çocukların sağlık düzeylerinin koruma ve geliştirmede önemli rolü olan ebelerin bu konuda ebeveynlerde ve çocuklarda farkındalık oluşturmaları, gerekli eğitim ve bilgilendirme girişimlerinde bulunmaları ve konuya ilişkin güncel çalışmaları takip etmeleri önerilebilir.

Anahtar Kelimeler: Dijital Bağımlılık, Çocuk, Ebe

Ebelik Mesleğinde Yeni Bir Bakış Açısı: Girişimcilik

Fatma Nur AYDIN¹, Ayşegül UNUTKAN²

Özet

Bu derlemede, girişimciliğin ebeler için önemini ilgili literatür doğrultusunda incelemek amaçlandı. Yeni bir iş fikri ile ekonomik değer oluşturmak, mevcut fırsatları en iyi şekilde değerlendirmek ve farklı fikirlerin aksiyon alması girişimcilik olarak adlandırılmaktadır. İnsanların sağlık konularında artan ve yeni ihtiyaçlarına etkin bir şekilde yanıt verebilmek için sağlık profesyonellerinin hastaneden topluma kadar bilgilerini geliştirmeleri ve bakımın farklı düzeylerinde girişimci rol üstlenebilecek donanıma sahip olmaları gerekmektedir. İlgili literatür incelendiğinde hemşirelerin girişimcilik düzeylerini araştıran çok sayıda çalışma olduğu ancak ebelik alanında bu konularda yapılan çalışma sayısının sınırlı olduğu görüldü. Sağlıktaki teknolojik gelişmeler, ebelerin mesleki profesyonelliğini artırmak amacıyla yenilikçi yaklaşımları ve girişimcilik faaliyetlerini de beraberinde getirmektedir. Yenilikçi bakış açısına sahip olan ebeler farklı bakış açılarıyla kanıta dayalı uygulamaları geliştirerek sunduklarını hizmetin kalitesini artırabilirler. Girişimci özellik taşıyan ebeler ise yüksek iletişim performansının yanında vizyon sahibi, farklı fikirlere kolaylıkla çözümler üretebilen, başarı odaklı ve lider ruhlu karakteristik özelliklere sahiptirler. Girişimcilik geliştirilebilir bir özelliktir ancak çalışmalara bakıldığında sağlık profesyonellerinin girişimciliklerinin ve yenilikçilerinin çok desteklenmediği anlaşılmaktadır. Bu nedenle, ebelerin girişimciliklerini geliştirmelerinin önündeki engellerin ve sınırların anlaşılması için çalışmaların yapılmasına ihtiyaç vardır. Ebelerin girişimcilik yolunda önünün açılması için lisans eğitiminden itibaren desteklenmesi, gerekli eğitimlerin ebelik müfredatına dâhil edilmesi, çeşitli atölye çalışmaları, yarışmalar ve programların düzenlenmesi fayda sağlayabilir.

Anahtar Kelimeler: Ebe; Ebelik; Girişimcilik; Ebelikte girişimcilik; Yenilik.

1 Ebelik ABD Yüksek Lisans Öğrencisi, KSBÜ Sağlık Bilimleri Üniversitesi, fnur.aydin@ogr.ksbu.edu.tr, ORCID İD 0000-0001-9273-8675

2 Dr. Öğr. Üyesi, KSBÜ Sağlık Bilimleri Üniversitesi, aysegul.unutkan@ksbu.edu.tr, ORCID iD 0000-0002-0311-2177

A New Perspective In Midwifery Profession: Entrepreneurship

Fatma Nur AYDIN, Ayşegül UNUTKAN

Abstract

In this review, we aimed to examine the importance of entrepreneurship for midwives in line with the relevant literature. Creating economic value with a new business idea, making the best use of existing opportunities and taking action on different ideas are called entrepreneurship. In order to respond effectively to the increasing and new needs of people in health issues, health professionals need to improve their knowledge from the hospital to the community and be equipped to assume an entrepreneurial role at different levels of care. When the relevant literature was examined, it was seen that there were many studies investigating the entrepreneurship levels of nurses, but the number of studies on these issues in the field of midwifery was limited. Technological developments in health bring along innovative approaches and entrepreneurial activities in order to increase the professionalism of midwives. Midwives with an innovative perspective can improve the quality of the service they provide by developing evidence-based practices with different perspectives. Midwives with entrepreneurial characteristics have high communication performance as well as visionary, success-oriented and leader-spirited characteristics that can easily produce solutions to different ideas. Entrepreneurship is a trait that can be developed, but when we look at the studies, it is understood that the entrepreneurship and innovativeness of health professionals are not supported much. Therefore, there is a need to conduct studies to understand the barriers and limits to midwives' entrepreneurship development. In order to pave the way for midwives on the path of entrepreneurship, it may be beneficial to support them from undergraduate education, to include the necessary trainings in the midwifery curriculum, to organize various workshops, competitions and programs. Keywords: Midwife; midwifery; entrepreneurship; entrepreneurship in midwifery; innovation.

Özet

İnovasyon sadece yenilik değil yeniliğin ortaya çıkmasında geçen tüm zamanı kapsar ve bu değişimde ortaya çıkan sonucu da odak noktası haline getirir. Bu derlemenin amacı hemşirelik eğitimde inovatif yöntemlerin neler olduğu ve inovatif uygulamaların faydalarıyla beraber bu yöntemlere engel olan unsurların nasıl çözülebileceğini ortaya koymaktır. İnovasyon kavramı geçtiğimiz yıllarda sağlık hizmetlerinin de seçimi haline gelmiştir. Halkın yaş alması, kronik hastalıkların çoğalması ve bu sebeplerden ötürü iyileştirme girişimlerinin değişmesi, bakımla beraber bu bakımların özelliklerine olan tutum ve davranışları da değiştirmiştir. Bu uygulamayı biliminin gelişmesiyle beraber üniversite öğrencilerinin de istekleri ve bakış açıları değişmektedir ve inovasyonun eğitimde var olması mecburiyet haline gelmektedir. Eğitimde inovasyon kültürü oluşturulurken eğitimin önemli katılımcıları olan öğrencilerin inovasyona olan bakış açıları değerlendirilmelidir. Öğüt verici, geleneksel eğitimler iletişim yetkinliğinde etkisizdir. İnovatif bir yöntem olan sanal hastalar, varlığı sayıca sınırlı olmayan tecrübelerle güvenli alanlarda aktiflik sağlaması ve özüne mahsus hastane ortamı olguların simülasyonu yetkinlikleri dikkate alındığında sanal rehberlik uygulaması hemşirelik bölümü öğrencilerinin iletişim yetkinliklerinin ilerlemesinde mükemmel bir programdır. Bir diğer yöntem ise chat-bot kullanımınıdır. Öğrenciler, ChatGPT'nin yapay zekâ özelliklerini kendilerine özel hale getirerek öğrenme tecrübelerine yönelik araştırma ve özet haline getirme özelliğini kullanabilirler. Sonuç olarak bu yöntemlerin kullanılabilmesi için yenilik gerekmektedir. Yenilikçilik olmadan inovasyon girişimleri hemşirelik bakımına entegre edilemez. Eğitimle inovasyonun birleşmesi için bu durumda da öğrencileri yeniliğe hevesli olmaları gerekmektedir.

¹Kütahya Sağlık Bilimleri Üniversitesi, Hemşirelik Bölümü Öğrencisi

Tıp Eğitiminde Yapay Zeka Ürünlerinin Kullanımına Etik Bakış

Nuriye DEĞİRMEN¹, Şeyda Ferah ARSLAN², Ayşe Sena DEĞİRMEN³

Özet

Yapay zeka ürünleri günümüzde birçok alanla birlikte eğitim alanında da kullanılır hale gelmiştir. Eğitim öğretim planlanmasına yönelik çalışmalarda, yardımcı bilgisayar uygulamaları iş yükünü azaltmıştır. Yapay zeka ürünlerinin laboratuvarlarda kullanılmaya başlanması, öğrenci-robot etkileşiminde eğitimi kolaylaştırmıştır. Bununla birlikte yapay zeka uygulamaları eğitim amaçlı video deneyimlerini pratikleştirerek eğitim hayatımıza sunmuştur. Ayrıca öğrencilere dönük özelleşmiş, farklılığı olan öğrencilere yönelik bireyci programlar yapay zeka ile yapılmaya başlanmıştır. Tıp eğitiminde otomatik değerlendirmeye dair bilişim odaklı sistemler kullanılmaya başlanmıştır. Sınav sonuçlarının değerlendirilmesinde, bilgisayarla öğrenci başarısını ölçme ve geri bildirim sağlamayı kolaylaştıran yapay zekaya dayalı otomatik test oluşturma sistemleri önemli fırsatları eğitimcilere sunmaktadırlar. Yapay zeka ile eğitimde verilerin analizleri ve veri madenciliği kolaylaşmıştır. Eğitimde kendi kendine çalışan robotların, insan gücü olmaksızın kullandığımız yapay zeka araçlarının insanlara maddi ve manevi zarar verebileceği hususu endişe vericidir. Asıl sorunsal; düşünen makinelerin “ahlaki statü”leri ile ilgilidir. Yapay zeka ürünleri ile ilgili etik sorunlardan biri inovasyon sistemlerinin eğitime entegrasyonunda maliyet sorunlarının olabilmesidir. Bilgisayar ortamında gerçekleştirilmiş ders programları ve ölçme değerlendirme sonuçlarının güven eksikliğine yol açabilmesi konusu da ayrı bir etik sorundur. Eğitimcilerin bizzat yaptığı birçok işin ortadan kalkmasına neden olmaktadır. Öğrencilerin verilerinde gizlilik eksikliğine sebep olabilir. Kişisel verilerde kötü kullanılma olasılığı da göz ardı edilmemelidir. Laboratuvarda robotik eğitimin insan gibi tam anlamıyla duygusal olamaması, hasta değerlendirmesini öğrenmede öğrencilerde algı eksikliğine sebep olabilmektedir. Veri analizinde ön yargılara ve ayrımcılıklara sebep olabilmesi de etik açıdan eğitim ortamlarını zora sokmaktadır. Veri analizi ve kodlamasının bireysel özerklikte kayba yol açabilmesi konusu da düşündürücüdür. Eğitim ortamında yapay zeka ürünlerinin insan temasının azaltılmasına yol açması ayrıca

¹ Kütahya Sağlık Bilimleri Üniversitesi, Tıp Fakültesi, Deontoloji ve Tıp Tarihi Anabilim Dalı, Kütahya, Türkiye

² Kütahya Sağlık Bilimleri Üniversitesi, Tıp Fakültesi, Tıp Eğitimi ve Bilişimi Anabilim Dalı, Kütahya, Türkiye

³ Kastamonu Üniversitesi, Eğitim Fakültesi, Sınıf Öğretmenliği Bölümü, Kastamonu, Türkiye

düşünülmelidir. Verileri son kullanıcıların yanlış kullanımlarının öğrencilere dair temel insan haklarının ihlaline yol açabilmesi konusu farklı bir etik sorundur. Robotların ve bilgisayarların kullanımı eğitimde insana dair sorumluluk eksikliğine sebep olabilmektedir. Karar vermede insan faktörünün kaybına yol açabilir. Tüm yararlarına karşın yapay zeka ürünlerinin tıp eğitiminde kullanımının, etik boyutuyla bu tür sorunları beraberinde getirmesi durumu; “Acaba yeni etik kurallara mı yönelmemize ihtiyaç var?” sorusunu gündeme getirmektedir.

Anahtar kelimeler: Etik, Tıp eğitimi, Yapay zeka

Hasta Eğitiminde İnovatif Yaklaşımlar

Beyhan TUNA¹, Fadime TASMAKIRAN¹, Berru ŞENOL¹, Yaren AŞIK¹, Sıla KAHRAMAN¹, Kamile ÇANKAYA¹, Beyda KOCABAŞ¹, Yağmur TUTAR¹

Gelişen ve ilerleyen sağlık bakım hizmetleri artan maliyet ve ihtiyaçlar doğrultusunda sağlık kurumlarının ekonomik, etkili ve kanıta dayalı bir bakım için inovasyon uygulamalarını tercihe sürüklemiştir.

İnovasyon, hemşirelik bakımında kanıta dayalı uygulamalarının ve kalitenin sürdürülmesinde büyük yer kaplamaktadır. İnovatif uygulamalar hemşirelik bakımından hem hastane maliyetini azaltarak hem de hemşirenin iş yükünü azaltarak hastalara ayrılan hemşirelik bakım süresini ve etkililiğini arttırmıştır. Bu sayede hastaların hastanede kalış süreleri kısaltmakta, hastanede kalış süresi boyunca konforlu bir tedavi süreci geçirmektedir.

Florance Nightingale'in yoğun bakım uygulamalarını başlatması, hemşirelik bakımının enfeksiyonla ilişkisi olduğunu kanıtlaması ve hemşirelik ile ilgili ilk kayıtları tutması hemşirelik bakımında inovasyonun ilk adımları olarak kabul edilmektedir.

Dünyanın birçok yerinde sağlık bakımı ve klinik uygulamalarında inovasyon desteklenmekte, hemşire liderleri ve yöneticileri inovasyonu meslektaşlarıyla paylaşarak hemşirelik bakım kalitesini artırmaya ve hemşirelik imajını geliştirmeye yönelik çalışmalar yapmaktadır. Türkiye'de inovasyon açısından atılan en önemli adım "İnovatif Hemşireler Derneği'dir." Derneğin amacı hemşirelik bakımını inovatif yaklaşımlara yönelen hemşirelere rehberlik etmektir. Hemşirelere inovatif fikirlerin geliştirilmesi, uygulanmaya konması, inovatif ürünlerin tanıtımı konusunda yardımcı olmaktadır. Dernek ulusal ve uluslararası sempozyum ve fuarlara katılarak inovatif gelişmeler açısından hemşireleri ve hemşirelik mesleğini temsil etmektedir. (inovatifhemşirelikdernegi.com)

Hemşirelikte İnovasyon Örnekleri

Kütahya Sağlık Bilimleri Üniversitesi, Hemşirelik Bölümü Öğrencisi

İnovasyon, hemşirelik bakımının iyileştirilmesinde önemli katkılar sağlamaktadır. Boston Tıp Merkezi ve Northeastern Üniversitesinin geliştirdiği sanal hemşire karakteri bilgisayar temelli taburculuk işlemlerine yardımcı olması için geliştirilen bir programdır. Hastalardan bilgi toplama, hastalara eğitim ve danışmanlık verme, hastanın sağlık durumunu değerlendirme ve taburculuk işlemlerini gerçekleştirme gibi hemşirelik aktiviteleri sağlamaktadır.

Sawatzky ve arkadaşları (2013) Kanada'da 500 yataklı üçüncü düzey bakım merkezinde yaptıkları çalışmada, kardiyak cerrahi hastalarının taburculuk sonrası yorgunluk, uyku bozukluğu, nefes darlığı, çarpıntı, iştahsızlık, hareket kısıtlılığı ve duygusal/psikolojik sorunlar yaşadıklarını ve hastaların taburcu olurken bu sorunlarla nasıl baş edeceklerine dair bilgi eksikliği olduğunu saptamışlardır. Ev ziyaretleri, telefonla hastanın takibi ve daha önce bu süreci atlatmış kişilerle görüşmeler yaparak hasta eğitimine katkı sağlamış ayrıca hastaların taburculuk sonrası geri dönüşlerinde azalma sağlamışlardır.

Cheryl Bailey ve ekibi, hastaların taburcu olduktan sonra yaşadığı sorunları ve hastaneye yeniden yatış sağlayan sorunları çözmek için elektronik ortamda hastaneye gitmeden çözümlene sağlayan bir yöntem geliştirmişlerdir. Elektronik ortamda hastaların taburculuk eğitimlerini sanal ortama yükleyerek, ev ortamında internet aracılığıyla öz bakım ve eğitim videolarına ulaşılabilen mobil sağlık programı geliştirmişlerdir. Bunun sonucunda hastalar, hasta yakınlarıyla etkili iletişim sağlanmıştır.

Hastalar taburculuk sonrası yanlış ilaç kullanımı ve istenmeyen ilaç etkileri sebebiyle hastaneye yeniden yatışın sağlanması sık karşılaşılan sorunlardandır. Bu durumu azaltmak ve taburculuk sonrası iyi bir ilaç eğitimi için Ruggiero ve arkadaşları (2015), tıbbi veya cerrahi tedavi sonrası kullanılacak ilaçları düzenleyen bir protokol geliştirmişlerdir. Hastaların kullandıkları ilaçların dozları, taburculuk sonrası kullanacakları ilaçlar ve sıklığı gibi kontrol adımlarını içeren protokol hastanın doğru dozda ve uygun ilaçla hastaneden taburcu olmasını sağlamıştır. Bu protokol sayesinde hastaların yanlış ilaç kullanma olasılığının azaldığı belirlenmiştir.

Hasta Düşme Eğitimi Optimize Etmek İçin Bakım İş Gücünün Yeniden Tasarlanmasının Uygulanabilirliği

Düşmeler hastanelerde sık görülen ve önlenemez bir sorundur. Kayıtlı sağlık çalışanları tarafından yapılan çalışmalardan elde edilen sonuçlara göre hasta eğitimi hastane düşmelerini azaltmak için oldukça önemli bir müdahaledir. Kişiselleştirilmiş düşme önleme eğitim

müdahalesini içeren hasta eğitimi çalışmalarının hastanelerde oldukça etkili olduğu görülmesine rağmen, personel hastaneye kabulden hemen sonra düşme eğitimini uygulamamaktadır. Bunun için alternatif bir yaklaşım olarak, nitelikli sağlık çalışanların gözetimi altında düşme önleyici eğitim vermek amacıyla yardımcı sağlık asistanları, hemşire asistanları veya kişisel bakım asistanları gibi kişileri kullanarak bakımdaki bu boşluğu kapatmak adına bir çalışma gerçekleştirmişler. Bu çalışmanın amacı, hastanın hastaneye kabulünden sonraki ilk 48 saat içinde normal bakımına ek olarak kanıta dayalı, yazılı hasta düşme eğitimi vermek üzere eğitilmiş asistanlar kullanarak hastanedeki düşme oranlarını azaltmak için bakım ve iş gücünün yeniden tasarlanmasının uygulanabilirliğini araştırmak. Sonuç olarak normal bakımın, yardımcı sağlık asistanları tarafından verilen hasta eğitimleriyle desteklenmesi mümkün ve faydalı gözükmektedir.

Chatbot ve Hasta Eğitimi

Yapay Zekâ ve Hemşirelik Eğitimi Chat Generative Pre-trained Transformer kısaca Chat GPT kullanıcılarla ince detaylara yer vererek iletişime geçebilen bir çeşit yapay zekadır. Eğitim amacıyla bilgi almak ve yazılı metinleri düzenlemek amacıyla kullanılmaktadır. AI-chatbot yönetsel işlere destek sağlar ve var olan zorlukları azaltarak hemşirelerin hasta bakımına yönelik zaman dilimine etki eder ve bakım hizmetlerinde dikkat seviyesinin artmasına yardımcı olur. Chat GPT birçok bölümde birden fazla akademik ve mesleki şartlara yeterli olup olmadığını sınavan testte geçer not almıştır. Son zamanlarda Singapur devleti, Microsoft Office ve Visual Studio gibi şirketler de Chat GPT 'den yararlanacağını belirtmiştir. Böyle kabul edilen Chat GPT hemşirelik alanına da birçok yarar sağlayacak ve zorlukların azaltılmasına sebep olacaktır. Patel Lam (2023) klinikte hastaların taburculuk işlemlerinin dokümanlarının yazılması için AI- chatbotu önermiştir. Bu sayede idari işlemlerin aldığı zaman kısalacak ve hemşirelerin bakıma yönelik zamanları artacaktır. Chat GPT tabanında birçok kitap, makale, web sitesi barındırması ile kullanıcıları tarafından geçer not almıştır. Arayüzü basit ve sade olduğundan her yaş grubu için kullanımı oldukça kolaydır. Ulaşılmak istenen bilgi arama kısmına yazıldığında 1 dakikadan kısa bir sürede aranan konu hakkında açıklayıcı ve anlaşılır bir metne ulaşılabilir. Chat GPT nin bünyesindeki kaynaklar 2021 yılı ve öncesine ait olduğundan özellikle başta hemşirelik olmak üzere güncel bilgiye ulaşmanın önemli olduğu diğer meslek gruplarında ve akademik çalışmalarda kaynakların güncelliğini kontrol etmek önem arz etmektedir. Covid-19 pandemisi sonrasında yapılan çalışmalarda yapay zeka destekli dijital sistemlerin özellikle demansı olan hastalar için kullanımının hastaların ruh sağlığı açısından geliştirici olabileceği ortaya çıkmıştır. Daha önce yapılan çalışmalarda ise yardımcı

robot teknolojisi kullanılmış ve bunun sonucunda hastalardaki ajitasyon davranışının azaldığı ve iletişimin arttığı, demansın davranışsal ve psikolojik belirtilerinin yönetiminde etkisi olduğu ortaya çıkmış dolayısıyla hemşirelerin iş yükü azalmıştır. Her geçen gün artan sağlık maliyetlerine karşın hastalar ve bakımverenler için daha ulaşılabilir olması, zamandan ve mekandan bağımsız olması ile kullanım rahatlığı sunan bu nonfarmakolojik yöntem terapötik amaçla da kullanılabilir. Tüm dünyayı sarsan pandemi süreci özelinde sosyal hayatta sınırlamaların olduğu, psikososyal destek almanın mümkün olmadığı durumlarda hastaların kendilerini daha iyi ve daha huzurlu hissetmelerini sağlamada uygun bir yöntemdir.

Tele Sağlık Hemşireliği

Sağlık bakım hizmetlerinden en fazla yararlanan yaşlılar oluşturmaktadır. Pandemiye yaşlı bireyleri sağlık bakım hizmetlerini karşılamakta zorluk yaşamıştır. Tele hemşirelik uygulamaları ile hemşireler yaşlıların sağlık durumlarını yakından takip edebilmekte ve sağlık sorunlarını erken tanılamakta, danışmanlık, eğitim ve evde bakım uygulamalarının yürütmektedir. Tele hemşirelik yaşlıların kendi yaşam alanlarında bakım gereksinimleri karşılamasını, bağımlılıklarının azalmasını, yaşam kalitelerinin yükselmesini ve topluma katılımlarını kolaylaştırmaktadır. Tele hemşirelerin bulunduğu ekip, uzaktan izlem ekipmanları sayesinde evlerinde olan yaşlıların takiplerini sağlayabilmektedir. Bu sayede yaşlıların evde bakımı daha uzun sürmekte kurum bakım ihtiyaçları azalmış olmaktadır. Tele hemşirelikte kullanılan cihazlarla yaşlıların genel sağlık taraması, kan basıncı, nabız, solunum fonksiyonu, vücut sıcaklığı, kan şekeri, kilo izlemi, kardiyak takipler, kandaki oksijen düzeyi, enfeksiyon belirteçleri takip edilebilmektedir. Giyilebilir sensörler özellikle bilişsel yetersizliği olan yaşlı bir birey evden çok uzaklaştığında tele sağlık ekibine uyarı vermekte böylece kaybolmaların önüne geçilerek güvenlik sağlanmaktadır. Eve yerleştirilen harekete duyarlı ışıklar ve titreşimi algılayan cihazlar ile düşmeler/kazalar önlenmekte veya erken müdahale edilebilmektedir. Tele psikiyatri hemşireliğinde danışmanlık, eğitim, sosyal destek hizmeti verilmekte, ilaçların kullanımı ve semptom yönetimi takibi yapılmaktadır. Tele yoğun bakım hemşireliğinde, klinik hemşireleri ile istasyonlarda bulunan yoğun bakım alanında tele yoğun bakım hemşireleri arasında bilgi aktarımını sağlanmaktadır. ” Dünyanın en güçlü e-sağlık hizmet sunumuna sahip olan Hollanda’da psikiyatri hastaları hastaneye başvurmadan teletıp yöntemi ile tedavi ve takip edilmekte; böylece hastalar hizmet almak için sıra beklemiyor, hastaneye yatış oranları azalıyor ve sağlık maliyetinde iyileşmeler söz konusu oluyor. İot tabanlı sağlık sistemi ile hastanın yanında bulunmadan yaşam bulguları, kilo ve fiziksel aktivite durumları hakkında aynı zamanda veri elde edilebiliyor. Böylelikle hastalar sağlıklarını kontrol etme ve yönetme

imkânı elde edebiliyor. Bu sistem veya iyileştirmeler lisansüstü eğitime bırakılmıştır , Yenilikçi bilgi, beceri ve tutumlarının lisans müfredatında eğitimin verilmemesi, gelecekteki her lisans mezunu hemşirenin gelişme fırsatını yakalayamadığı anlamına gelir.

Emzirme Danışmanlığında Yenilikçi Yaklaşımlar Ve Teknolojinin Kullanımı

Anne sütü, bebekler için şüphesiz en önemli besin kaynağıdır ve sağlıkları için oldukça faydalıdır. Bebeklerin anne sütünde var olan eşsiz özelliklerden faydalanabilmesinin yolu emzirilmeleridir,

Emzirme eğitimlerinde yenilikçi, güncel ve teknolojiye dayalı eğitim yöntemlerinin kullanımı giderek artmaktadır. Yenilikçi yaklaşımlardan bazıları web tabanlı sağlık eğitimleri, mobil sağlık uygulamaları, görüntülü sohbet veya evde konferans, kısa mesaj hizmeti, e-posta, dijital video gibi tele hemşirelik hizmetleri kullanılmaktadır. Bu ve bunun gibi uygulamalar özellikle yüz yüze görüşme imkanının sağlanamadığı durumlarda ve herkes tarafından eşit şekilde ulaşılabilir olması nedeniyle oldukça kullanışlıdır. Litratürde, tele sağlık müdahalelerinin emzirme sonuçlarını olumlu yönde etkilediği (DeNicola et al., 2020), videolu emzirme eğitiminin daha etkili sonuçlar verdiği (Kırık vd., 2022), kısa mesaj ve telefon aramaları ile taburculuk sonrası süreç için de emzirme davranışının desteklenmesinde annelerin emzirme davranışını doğru yaptığı ve yalnızca anne sütü verme davranışını olumlu etkilediği (Gölbaşı vd., 2019), planlı davranış teorisine dayalı uygulanan emzirme eğitim programının emzirme oranlarını olumlu yönde artırdığı (Arshad et al., 2017), Bandura'nın özyeterlilik teorisine ve Dennis'in emzirme özyeterlilik kuramına dayalı emzirme danışmanlığının annelerin doğru emzirme oranları ve kendini yeterli hissetme puanlarını artırdığı (Liu et al., 2017), öğrendiğini anlat yöntemiyle verilen emzirme eğitiminin emzirme öz yeterliliğini artırma ve emzirme başarımının sağlanmasında etkili bir yöntem olduğu (Kuluçtu ve Özerdoğan, 2020) bildirilmektedir.

Hemşirelerin, teknolojinin yararlarından ve pratikliğinden fayda sağlayarak, emzirme oranlarının olumlu yönde artmasına ve anne, bebek ve toplum sağlığının gelişmesine ve olumlu yönlerde katkı sağlayacağı düşünülmektedir.

Sonuç Ve Öneriler

İnovatif uygulamalar, hemşirelikte kanıta dayalı uygulamaların ve bilgi birikiminin artmasının yanı sıra hemşirelik uygulamalarında maliyeti düşürmektedir. İnovatif

uygulamalarla hemşirelik bakımının kalitesi de artmaktadır. Bu nedenler hemşirelikte inovasyon uygulamalarının geliştirilmesini doğurmaktadır. İnovasyon Uygulamalarının beklenen gelişmeyi göstermesi inovasyon kültürünün oluşturulması ile mümkündür. İnovatif gelişme kültürünün gelişmesi için akademisyen hemşirelerin eğitim programlarını inovatif düşünmeyi destekleyecek şekilde düzenlemeleri gerekmektedir. Yükseköğrenim öğrencilerinin profilindeki değişimler ve beklentiler eğitimde inovatif yaklaşım ihtiyacını ortaya koymaktadır. Dünya Sağlık Örgütü ,eğitim süreci için hemşirelik okullarının programlarında inovatif eğitim teknikleri, elektronik öğrenme ve simülasyon yöntemlerinin kullanılmasını önermektedir. İnovasyon sürecinin, hemşirelik uygulamalarındaki etkinliğinin artmasında hemşire lider ve yöneticiler tarafından iyi anlaşılması gerekmektedir. Kurumda inovasyon uygulamalarının artırılmasında yönetici hemşirelerin öncülük etmesi kilit noktadır. İnovatif projelere yeterli kaynağın bulunması ve fikirlerin ticarileştirilmesinde aracı olmalıdır. İnovasyonda kusursuzluğun sağlanmasında çalışanların, inovasyona yönelik olarak eğitilmesi, inovatif düşünceler geliştirmeleri konusunda desteklenmeleri ve uygun ödül sistemi ile ödüllendirilmeleri gibi işlevlerde yönetici hemşirelere büyük sorumluluklar getirmektedir. Hemşirelikte inovasyonun geliştirilmesinde hemşirelik örgütlerinin desteklenmesi ve yasal süreçlerde hemşirelerin desteklenmesi gerekmektedir. Yönetici ve lider hemşirelerin yol gösterici olarak büyük sorumlulukları vardır.

KAYNAKÇA

1. Akpınar Söylemez, B. Özgül, E. (2022). Yaşlılarda Tele Hemşirelik Uygulamaları. İzmir Katip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi, 7(3), 619-62
2. Çam, F. İstanbul Üniversitesi, İç Hastalıkları Hemşireliğinde Yenilikçi Yaklaşımlar ,(2021),Cilt 1, Sayı 2
3. Kartal, H. Kantek, F. (2018). Hemşirelikte İnovasyon Örnekleri. Sağlık ve Hemşirelik Yönetimi Dergisi, 5(1), 1-7 https://jag.journalagent.com/shyd/pdfs/SHYD_5_1_57_63.pdf
4. Morris, M. E., Thwaites, C., Lui, R., McPhail, S. M., Haines, T., Kiegaldie, D., ... & Hill, A. M. (2024). Preventing hospital falls: feasibility of care workforce redesign to optimise patient falls education. Age and Ageing, 53(1), afad250.
5. Tam, W. Huynh, T. Tang, A. Luong, S. Khatri, Y. Zhou, W. “Nursing education in the age of artificial intelligence powered Chatbots (AI-Chatbots): Are we ready yet?” Nurse Education Today, 129 (2023) 105917
6. Yıldız, A. Şahan, S. Günay İsmailoğlu, E. İzmir Kâtip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi ,Türkiye’de Üniversitelerin Hemşirelik Eğitiminde Kullandığı İnovatif Yaklaşımlar , 2022; 7(2):261-267
7. Temizkan, E. Ünsal,Ş. Kadın Sağlığı Hemşireliği Dergisi (KASHED), S-085 Emzirme Danışmanlığında Yenilikçi Yaklaşımlar ve Teknolojinin Kullanımı 2023; 9 (Özel Sayı-1);44-48

Geriatrik Bireylerin Yaşamında Kolaylaştırıcı İnovatif Uygulamalar

Aynur Demir¹, Gülistan Almaz¹, Emine Beyza Kayar¹, Zerrin Yalçın¹, Kadriye Aslan¹,
Gülçin Arslan¹

Özet

Günümüzde teknoloji hızla birçok alanda yerini almış ve yaygınlaşmıştır. Bu alanlardan biri de bizler için önem arz eden ve toplumda sayıları gittikçe artan geriatrik kesimdir. Geriatrik bireyler birçok hastalıkla mücadele etmeleri sebebiyle bu hastaların bakım ihtiyaçları diğer bireylere oranla daha fazladır. Bu yüzden inovatif yaklaşımlar ve sağlığı kesiştiren birtakım teknolojik mobil uygulamalar ve teknolojik aletler geliştirilmiştir. Geliştirilen bu projeler yeterli donanımlara sahip olması, kullanılabilirliğinin kolay olması, ulaşılabilir olmasıyla yaşlı bakım kalitesinde önemli düzeyde artış olacağı öngörülmektedir. Teknolojik mobil uygulamalar ve teknolojik aletlerin amaçları; geriatrik hastaların kendi kendilerini yönetmelerine yardımcı olmak ve bu sayede bağımlılık düzeyleri azaltmak, başka bireylere olan bakım ihtiyaçlarını azaltmak ve hastalık yönetimini kolaylaştırmaktır. Geriatrik hastaların öz bakım ihtiyaçlarının kolaylaştırılması, zaman tasarrufunun sağlanması, psikolojik yönden stres ve anksiyete seviyelerini azaltılması, hastaların düzenli takiple hastalıklarını daha iyi yönetebilmesi, sağlık hizmetlerine erişimin kolaylaştırılması ve yaşam kalitelerinin iyileştirilmesi gibi avantajları vardır. Bunun yanı sıra yaşlı bireylerin teknolojiyi kullanmada yetersiz bilgiye sahip olmaları, hastaların uzaktan muayene edilememesi, bu teknolojilerin finans desteğinin sağlanamaması, geriatrik hastalarda eve hapis olma düşüncesi ve sistemlerde hata olabilmesi gibi dezavantajları da bulunmaktadır. Avantajları dezavantajlarından fazla olmasından kaynaklı günümüzde kullanılmaktadır.

KAYNAKÇA

1. Söylemez.B.,Özgül.E.,(2022). Yaşlılarda Tele Sağlık Uygulamaları.İzmir Katip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi.7(3),619-622.
2. Cisse.Lt.,Yılmaz.Ö.,(2022). Yaşlıları Günlük Yaşlıları Günlük Yaşamlarında Destekleyici Mobil Sağlık Uygulaması Geliştirilmesi.Avrupa Bilim Ve Teknoloji Dergisi.(34),601-609.

¹Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü Öğrencisi

3. Ustamehmetođlu.G.,(2021). Akıllanan Dñnyada Yaşılı Bakım Uygulamaları. Fenerbahçe Üniversitesi Sađlık Bilimleri Dergisi.1(1),53-61.
4. Dñnmez.Ö.K.,Şahin.D.S.(2021).Yaşılı Bakımına İnovatif Bir Yaklaşım: Geronteknoloji.Burdur Mehmet Akif Ersoy Üniversitesi. Lipdiz Türkçe Konferans Koleksiyonu.(4),39-46.
5. T. (2019). Natural Fibresandthe World Economyjuly 2019. https://Dnfi.Org/Coir/Natural-Fibres-And-The-World-Economy-July-2019_18043/
6. Young, S. (2019). The Real Cost Of Yourclothes: These Are The Fabrics With The Best And Worst Environmental İmpact.

Özet

Ülkemizde Sağlık Bakanlığı ebeyi kadın ve bebekle ilgilenen sağlık görevlisinin dışında aile planlaması yapan eğitim veren bir çalışan olarak tanımlanmaktadır (1). Ebenin tüm bunları yapabilmesinde aldığı eğitimin önemi büyüktür. Bir ebenin yüksek kalite bakım verebilmesi için yüksek kalitede eğitim alması gerekmektedir (2). Ebelik eğitiminin kaliteli ve yüksek standartlarda olması bakımı arttırırken anne bebek ölümünün de önemli oranda önüne geçmektedir (3). Geleneksel sağlık hizmetleri eğitimi; rol modelleme, ders kitapları, e-öğrenme, seminerler, hakemli dergi makalelerinin okunması gibi uygulamalar içerir. Deneyimsel olarak ise öğrencilerden önce gözlemlenmesi sonra uygulaması beklenmektedir. Bu durum da hastaları deneyimsiz sağlık uygulayıcılarına maruz bırakırken uygulamayı tehlikeli ve zararlı hale getirmektedir (4). Bilgi teknolojilerinin ortaya çıkışı, eğitimecilere, öğrencileri öğrenme deneyimine kolaylaştıracak ve katılımlarını sağlayacak yeni kaynaklar sağlamıştır (5). Sağlık alanı dinamik bir yapıya sahiptir. Bu dinamiklik eğitime de entegre edilmelidir çünkü öğrencilerinin sürekli yeniliğin olduğu bir sisteme uyum sağlaması için eğitimin de yenilikçi ve inovatif olması gerekmektedir (6). Aynı zamanda da mesleğinde inovatif bireylerin yetişmesi için öğrencilerin inovasyon kavramı hakkında bilgili olması ve inovatif eğitim alması gerekmektedir (7). Ancak sağlık ve bakım çalışanlarına beceri kazandıran dijital müdahalelere yönelik uygulama stratejilerine ilişkin literatür sınırlıdır. Eğitimde inovasyon sanal gerçeklik, artırılmış gerçeklik ve karma gerçeklik eğitim programlarını içerir. Sanal gerçeklik kullanıcıların gerçekte olmayan şeyleri oluyormuş gibi hissettiren teknolojidir. Nesnelere etkileşime girme ve dijital dünyada eylem gerçekleştirme yeteneği sayesinde eğitimde kullanılabilir (8,10). Artırılmış gerçeklik programları, sanal gerçeklik ile gerçekliğin bir arada kullanılması ile ortaya çıkan bir teknolojidir. Hem gerçek hem sanal nesnelere aynı ortamda birleştirir, hızlar ve bunları etkileşimli ve gerçek zamanlı olarak yapar böylece öğrencilerin

¹Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Ebelik Bölümü Öğrencisi

²Arş. Gör., Kütahya Sağlık Bilimleri Üniversitesi, Sağlık Bilimleri Fakültesi, Ebelik Bölümü, imranulku.alev@ksbu.edu.tr, ORCID: 0009-0009-4962-124X

gerçek hayatta deneyimleyemeyecekleri birçok şeyi deneyimlemelerine olanak sağlar. Bu nedenle eğitimde kullanılması faydalıdır (11-13). Karma gerçeklik ise artırılmış ve sanal gerçeklikten sonra çıkarak, geliştirilmiş bir artırılmış gerçeklik deneyimi olarak ifade edilebilmektedir. Öğrencilerinin teorik bilgide yetkin olma, çeşitli klinik beceriler geliştirme ve klinik akıl yürütmeyi pekiştirme becerilerini geliştirme ihtiyacına yardımcı olabilir. Ayrıca, öğrencilerin karmaşık fikirleri ve durumsal farkındalığı anlamalarını geliştirebilecek aktif katılımı ve özerk araştırmayı teşvik etme potansiyeline sahiptir (14-16). Ebelik eğitimine karma gerçekliğin entegre edilmesinin faydalı olacağı öngörülmektedir.

Anahtar Kelimeler: Ebelik eğitimi; karma gerçeklik, sanal gerçeklik.

KAYNAKÇA

1. Sağlık Meslek Mensupları ile Sağlık Hizmetlerinde Çalışan Diğer Meslek Mensuplarının İş ve Görev Tanımlarına Dair Yönetmelik. (2014). T.C. Resmî Gazete, 29007, 22 Mayıs 2014.
2. Yılmaz, S. D., & Aksoy, Y. E. Ebelik eğitiminin dünyadaki durumu. *Ebelik ve Sağlık Bilimleri Dergisi*, 1(1), 26-31.
3. Ball, K. L., Peacock, A. S., & Winters-Chang, P. (2022). A literature review to determine midwifery students' perceived essential qualities of preceptors to increase confidence and competence in the clinical environment. *Women and birth journal of the Australian College of Midwives*, 35(3), e211–e220.
4. Reznick, R. K., & MacRae, H. (2006). Teaching surgical skills—Changes in the wind. *The New England Journal of Medicine*, 355(25), 2664-2669. <https://doi.org/10.1056/NEJMr054785>
5. Malik, G., McKenna, L., & Plummer, V. (2015). Perceived knowledge, skills, attitude and contextual factors affecting evidence-based practice among nurse educators, clinical coaches and nurse specialists. *International Journal of Nursing Practice*, 21 Suppl 2, 46-57. <https://doi.org/10.1111/ijn.12366>
6. Veer V, Phelps C, Moro C. Incorporating Mixed Reality for Knowledge Retention in Physiology, Anatomy, Pathology, and Pharmacology Interdisciplinary Education: A Randomized Controlled Trial. *Med Sci Educ*. 2022 Sep 23;32(6):1579-1586. doi: 10.1007/s40670-022-01635-5.
7. Ceylantekin, Y., & Öcalan, D. (2022). Hemşirelik öğrencilerine verilen inovasyon eğitiminin yenilikçilik düzeylerine etkisi. *Yükseköğretim ve Bilim Dergisi*, 12(2), 324-333.
8. Bouraghi H, Mohammadpour A, Khodaveisi T, Ghazisaeedi M, Saeedi S, Familgarosian S. Virtual Reality and Cardiac Diseases: A Systematic Review of Applications and Effects. *J Healthc Eng*. 2023 May 30; 2023:8171057. doi: 10.1155/2023/8171057.
9. Bülbül, H., & Ersöz, B. (2022). Eğitimde yapay zekâ sanal gerçeklik ve sanal evren (Metaverse). *Yapay zekâ ve büyük veri kitap serisi* (4. Baskı, s. 149-183) içinde. Nobel Akademik Yayıncılık.
10. Chen FQ, Leng YF, Ge JF, Wang DW, Li C, Chen B, Sun ZL. Hemşirelik Eğitiminde Sanal Gerçekliğin Etkinliği: Meta-Analiz. *J Med İnternet Arş*. 2020 Eylül 15;22(9):e18290. doi: 10.2196/18290.

11. Rodríguez-Abad C, Fernández-de-la-Iglesia JD, Martínez-Santos AE, Rodríguez-González R. A Systematic Review of Augmented Reality in Health Sciences: A Guide to Decision-Making in Higher Education. *Int J Environ Res Public Health*. 2021 Apr 17;18(8):4262.
12. Çiloğlu, T., Yılmaz, Ö., Yılmaz, A., & Karaoğlu, F. (2021). Eğitimde artırılmış gerçeklik konulu makalelerin incelenmesi. *Ahmet Keleşoğlu Eğitim Fakültesi Dergisi*, 3(2), 147-158.
13. Pottle J. Virtual reality and the transformation of medical education. *Future Healthc J* 2019;6:181–5.doi:10.7861/fhj.2019-0036
14. Ryan, G., Callaghan, S., Rafferty, A., Murphy, J., Higgins, M., Barry, T., Mangina, E., Carroll, L., & McAuliffe, F. (2022). Virtual reality in midwifery education: A mixed methods study to assess learning and understanding. *Nurse education today*, 119, 105573.
15. Garrett, B. M., Anthony, J., & Jackson, C. (2018). Using mobile augmented reality to enhance health professional practice education. *Current Issues in Emerging eLearning*, 4(1), 10.
16. Frost, J., Delaney, L., & Fitzgerald, R. (2020). Exploring the application of mixed reality in Nurse education. *BMJ simulation & technology enhanced learning*, 6(4), 214–219. <https://doi.org/10.1136/bmjstel-2019-000464>

Kütahya Sağlık Bilimleri Üniversitesi Yayınları